

**ANALISIS PERKIRAAN BEBAN PUNCAK ENERGI LISTRIK
MENGUNAKAN MODEL GJR-GARCH**



SKRIPSI

*Diajukan untuk Memenuhi Salah Satu Syarat Meraih Gelar Sarjana Matematika
Jurusan Matematika pada Fakultas Sains dan Teknologi
UIN Alauddin Makassar*

Oleh:

NURZARINA

NIM. 60600113057

**JURUSAN MATEMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI ALAUDDIN
MAKASSAR
2018**

PERNYATAAN KEASLIAN SKRIPSI

Dengan penuh kesadaran, penyusun yang bertanda tangan di bawah ini menyatakan bahwa skripsi ini benar adalah hasil karya penyusun sendiri. Jika di kemudian hari terbukti bahwa ia merupakan duplikat, tiruan, plagiat, atau dibuat oleh orang lain, sebagian atau seluruhnya, maka skripsi dan gelar yang diperoleh karenanya batal demi hukum.

Makassar, April 2018

Penyusun



NURZARINA
NIM : 60600113057

UNIVERSITAS ISLAM NEGERI
ALAUDDIN
M A K A S S A R

PENGESAHAN SKRIPSI

Skripsi yang berjudul “Analisis Perkiraan Beban Puncak Energi Listrik Menggunakan Model GJR-GARCH”, yang disusun oleh Saudari **Nurzarina**, Nim: **60600113057** Mahasiswa Jurusan Matematika pada Fakultas Sains dan Teknologi Universitas Islam Negeri (UIN) Alauddin Makassar, telah diuji dan dipertahankan dalam sidang *munaqasyah* yang diselenggarakan pada hari Rabu tanggal **28 Maret 2018 M**, bertepatan dengan **11 Rajab 1439 H**, dinyatakan telah dapat diterima sebagai salah satu syarat untuk memperoleh gelar Sarjana Matematika (S.Mat.).


Makassar, 28 Maret 2018 M
11 Rajab 1439 H

DEWAN PENGUJI

Ketua	: Prof. Dr. H. Arifuddin Ahmad, M.Ag.	(.....)
Sekretaris	: Risnawati Ibbas, S.Si., M.Si.	(.....)
Munaqisy I	: Wahidah Alwi, S.Si., M.Si.	(.....)
Munaqisy II	: Muh. Rusydi Rasyid, S.Ag., M.Ed.	(.....)
Pembimbing I	: Ermawati, S.Pd., M.Si.	(.....)
Pembimbing II	: Khalilah Nurfadilah, S.Si., M.Si.	(.....)

Diketahui oleh:

Dekan Fakultas Sains dan Teknologi
UIN Alauddin Makassar



Prof. Dr. H. Arifuddin Ahmad, M.Ag
Nip. 19691205 199303 1 001

MOTTO DAN PERSEMBAHAN

MOTTO

JIKA ORANG LAIN BISA KENAPA TIDAK DENGAN DIRIMU...

Sesungguhnya bersama kesulitan pasti ada kemudahan, maka apabila telah engkau selesai(dari suatu urusan), tetaplah bekerja keras (untuk urusan yang lain)

(Q.S Al-Insyirah:6)

Kupersembahkan Tugas Akhir ini Kepada :

Kedua Orang Tua, Ayah (Basri) dan Ibu (Sitti Aminah) yang tiada hentinya berjuang dengan keras untuk melihat anaknya berhasil dari mereka, menjadi orang tua yang paling cerewet ketika anaknya berbuat salah dengan menasehatinya, tak pernah berhenti memberikan cinta, kasih, sayang, doa serta petuahnya dan menjadi motivasi terbesar dalam penyelesaian tugas akhir ini.

Untuk ke 4 adik-adik tersayangku, Muh Jasmin, Muh Azhari, Nurfadilah dan Cahaya yang selalu menjadi alasan terkuatku untuk berhasil menjadi contoh terbaik untuk kalian. Tugas akhir ini kupersembahkan untuk kalian.

Kawan-kawan Big Stone, Math C, Sigma beserta partner kerja LabKomMat Squad yang telah mengajarkanku arti dari perjuangan yang pantang menyerah.

Almamater UIN alauddin Makassar

KATA PENGANTAR



*Alhamdulillah*hirabbil'alam. Puji syukur penulis panjatkan kehadiran Allah Subhanahu Wata'ala atas segala nikmat iman dan nikmat kesehatan serta Rahmat-Nyalah sehingga penulisan skripsi yang berjudul **“Analisis Perkiraan Beban Puncak Energi Listrik Menggunakan Model GJR-GARCH”** dapat diselesaikan. Salam dan shalawat dicurahkan kepada Rasulullah Muhammad Shallallahu 'alaihi Wasallam. beserta para keluarga, sahabat dan para pengikutnya yang senantiasa istiqamah dijalan-Nya.

Skripsi ini disusun sebagai salah satu syarat untuk memperoleh gelar Sarjana Matematika (S.Mat) pada Fakultas Sains dan Teknologi Universitas Islam Negeri Alauddin Makassar. Untuk itu, penulis menyusun tugas akhir ini dengan mengerahkan semua ilmu yang telah diperoleh selama proses perkuliahan. Tentunya dalam penulisan dan penyelesaian skripsi memiliki hambatan dan tantangan, namun berkat bantuan dari berbagai pihak terutama do'a dan dukungan yang tiada hentinya dari kedua orang tua tercinta yaitu ayahanda **Basri** dan Ibunda **Sitti Aminah** serta ke empat adik-adik tersayangku yaitu **Muh Jasmin, Muh Azhari, Nurfadilah dan Cahaya**. Serta mereka adalah tujuan utama dari pencapaian ini.

Ucapan terima kasih yang tulus serta penghargaan yang sebesar-besarnya penulis sampaikan kepada :

1. Bapak Prof. Dr. H A Qadir Gassing, HT.MS., M.A., selaku Rektor Universitas Islam Negeri (UIN) Alauddin Makassar.

2. Bapak Prof. Dr. H. Arifuddin Ahmad, M.Ag selaku Dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Alauddin Makassar beserta para wakil dekan atas segala fasilitas yang diberikan.
3. Bapak Irwan, S.Si., M.Si selaku ketua jurusan Matematika Fakultas Sains dan Teknologi Universitas Islam Negeri Alauddin Makassar yang selalu memberikan arahan kepada mahasiswanya untuk terus belajar dengan baik
4. Ibu Ermawati, S.Pd, M.Si selaku Pembimbing I dan Kepala Laboratorium Matematika yang tiada hentinya selalu memberikan motivasi, semangat, ilmu serta kasih sayangnya sebagai orang tua kedua penulis selama menjadi mahasiswa.
5. Ibu Khalilah Nur Fadilah, S.Si, M.Si selaku pembimbing II yang telah sabar memberikan bimbingan, meluangkan waktunya, memberikan ilmu, motivasi serta semangat dalam penulisan skripsi ini.
6. Ibu Wahidah Alwi, S.Si., M.Si selaku Sekertaris Jurusan Matematika dan Penguji I atas segala arahan, bimbingan, ilmunya, bantuannya serta kasih sayangnya selama penulis menjadi mahasiswa.
7. Bapak Muh. Rusydi Rasyid, S.Ag, M.Ed selaku Penguji II atas bimbingan serta sarannya dalam penulisan skripsi ini.
8. Para dosen-dosen dan staf Jurusan Matematika Fakultas Sains dan Teknologi Universitas Islam Negeri Alauddin Makassar dengan tulus dan ikhlas memberikan ilmu dan bantuannya kepada penulis.

9. Teman-teman“SIGMA”, posko KKN Reguler angkatan 55 Kecamatan Tombolo Pao Desa Erelembang (Erelembang Squad) dan teman-teman PKL serta Pegawai Kantor PLN PT(Persero) WILAYAH SULSELBAR atas segala bantuan terutama untuk pembimbing PKL yaitu bapak Taslim atas bantuan, doa dan motivasinya selama ini. Teman-teman Math C yang telah berjuang bersama sampai pada tahap akhir.
10. Teman-teman “The Big Stone” yaitu Mustika, Ratna Wulandari, Nova Nofianty K, Nurul Fitriani S dan Novita Sari yang telah berjuang bersama dari awal perkuliahan sampai pada tahap penyelesaian penulisan skripsi ini, yang telah memberikan banyak pelajaran dan saling menyemangati.
11. Kepala Labotarium, Laboran serta kawan-kawan asisten Laboratorium Komputer Matematika Fakultas Sains dan Teknologi Universitas Islam Negeri Alauddin Makassar yang telah menjadi partner kerja serta memberikan ilmu-ilmu, dukungan dan motivasinya.
12. Teman-teman asrama Fajar Mas yaitu Hijranah,S.Farm, Cici Namira Basri, S.Psi, Ulfa Diana Mustari, A.Md, Herny Baharuddin, S.Pd, Sadariah, S.Pd, Nurul Iqraini, S.Si, Irawati yang telah menjadi saudara seperantauan yang hidup bersama di atap yang sama saling tolong menolong satu sama lain dan telah memberikan bantuannya baik bantuan moril, motivasi maupun ilmu dan arahnya
13. Kepada semua pihak yang telah memberikan bantuan baik moril maupun materil hingga skripsi ini dapat diselesaikan.

Penulis menyadari bahwa tugas akhir ini masih jauh dari kesempurnaan, oleh karena itu, kritik dan saran yang bersifat membangun untuk kesempurnaan tugas akhir ini sangat diharapkan. Semoga tugas akhir ini membawa manfaat bagi kita semua dan terutama pengembangan ilmu pengetahuan. Amin.

Makassar, Maret 2018

Penulis

NURZARINA
NIM 60600113057



DAFTAR ISI

HALAMAN JUDUL	i
PERNYATAAN KEASLIAN SKRIPSI.....	ii
LEMBAR PENGESAHAN	iii
MOTTO DAN PERSEMBAHAN.....	iv
KATA PENGANTAR.....	v
DAFTAR ISI.....	ix
DAFTAR TABEL.	xi
DAFTAR LAMPIRAN.....	xii
DAFTAR SIMBOL.....	xiii
ABSTRAK.	xiv
BAB 1 PENDAHULUAN	
A. Latar Belakang	1
B. Rumusan Masalah	8
C. Tujuan	8
D. Batasan Masalah	8
E. Manfaat Penelitian	9
F. Sistematika Penulisan	9
BAB II TINJAUAN PUSTAKA	
A. Peramalan.....	11
B. Time Series	13
C. Stokastik dan Stasioneritas	15
D. ARIMA Box Jenkins	20
E. ACF (<i>Autocorrelation Function</i>) dan PACF (<i>Partial Autocorrelation Function</i>)	22

F. Metode Maximum Likelihood	23
G. Uji Signifiakansi Parameter	25
H. <i>Uji Augmented Dickey–Fuller</i> (ADF Test)	26
I. Proses White Noise	27
J. Model ARCH dan GARCH	28
K. Uji ARCH-LM	30
L. Model GJR-GARCH	31
M. <i>Uji Akaike Information Criterion</i> (AIC)	33
N. Beban Listrik	33
BAB III METODOLOGI PENELITIAN	
A. Jenis Penelitian	38
B. Waktu Penelitian	38
C. Jenis Data Dan sumbel Data	38
D. Variabel Dan Defenisi Operasi Variabel	38
E. Prosedur Penelitian	38
F. Flowcart	40
BAB IV HASIL DAN PEMBAHASAN	
A. Hasil	41
B. Pembahasan	54
BAB V PENUTUP	
A. Kesimpulan	58
B. Saran	58
DAFTAR PUSTAKA	xv
LAMPIRAN	
BIOGRAFI	

DAFTAR TABEL

Tabel 2.1 Nilai yang digunakan untuk transformasi	20
Tabel 4.1 Autokorelasi data beban puncak	43
Tabel 4.2 Uji <i>Augmented Dickey –Fuller</i> Data Beban Puncak <i>Differencing</i> Orde Pertama	45
Tabel 4.3 Nilai autokorelasi setelah <i>differencing</i> 1	46
Tabel 4.4 Nilai autokorelasi parsial setelah <i>differencing</i> 1	47
Tabel, 4.5 Estimasi Model ARIMA	49
Tabel 4.6 Uji ARCH-LM	51
Tabel 4.7 Pendugaan Parameter GARCH	52
Tabel 4.8 Hasil pendugaan Parameter GJR-GARCH	53
Tabel 4,9 Peramalan Data Beban Puncak	55

DAFTAR GAMBAR

Gambar 4.1 Grafik data Beban Puncak	42
Gambar 4.2. Grafik fungsi autokorelasi beban puncak	43
Gambar 4.3 Plot data beban puncak setelah <i>differencing</i> 1	44
Gambar 4.4 Plot ACF Beban puncak setelah proses <i>differencing</i> 1	46
Gambar 4.5 Plot PACF Beban Puncak setelah proses <i>differencing</i> 1	47



DAFTAR SIMBOL

$-$	= Pengurangan
$+$	= Penjumlahan
\times	= Perkalian
Z_t	= nilai variabel Z pada waktu t
ε_t	= nilai residual pada waktu t
p	= orde AR
d	= orde <i>differencing</i> non-musiman
q	= orde MA
ϕ_p	= parameter yang menjelaskan AR
θ_q	= parameter yang menjelaskan MA
B	= operator <i>backshift</i>
Δ^n	= hasil differencing pada nilai ke- n
σ_t^2	= nilai ragam residual
α_0	= nilai konstanta pada ragam
ε_{t-1}^2	= kuadrat residual yang lalu
α_p	= parameter ARCH, untuk $p = 1, 2, \dots, p$; dan $\alpha_p > 0$
β_q	= parameter GARCH, untuk $p = 1, 2, \dots, q$; dan $\beta_q > 0$
γ	= parameter GJR
K	= jumlah parameter dalam model
N	= jumlah observasi (sampel)

ABSTRAK

NAMA : NURZARINA

NIM : 60600113057

JUDUL : ANALISIS PERKIRAAN BEBAN PUNCAK ENERGY LISTRIK MENGGUNAKAN MODEL GJR- GARCH”

Energi listrik merupakan suatu kebutuhan dasar yang berperan penting dalam kehidupan masyarakat, dikarenakan dalam setiap peralatan elektronik yang digunakan oleh masyarakat membutuhkan listrik sebagai sumber energi. Peramalan beban puncak listrik merupakan suatu upaya yang dapat dilakukan untuk menstabilkan sistem energi listrik di daerah Makassar oleh PT PLN (Persero) Wilayah SULSELBAR. Pola konsumsi listrik yang berbeda membuat model peramalan *Glosten Jaganathan Rungkel Generalized Autoregressive Conditional Heterokedasticity* (GJR-GARCH) sangat cocok digunakan untuk data beban puncak energi listrik jangka pendek dikarenakan tingkat konsumsi listrik yang dilakukan oleh masyarakat itu berbeda-beda, sehingga variansnya mengalami kondisi heteroskedastisitas. Data historis yang digunakan adalah data pada periode 1 Januari 2016 sampai pada 31 Desember 2016. Tujuan dari penelitian ini yaitu untuk mengetahui bagaimana model peramalan GJR-GARCH dan hasil peramalan dari model tersebut dengan menggunakan data historis beban puncak listrik. Berdasarkan hasil penelitian maka diperoleh beberapa model yang digunakan dalam proses peramalan ini yaitu model ARIMA(1,1,1) dan model GJR-GARCH (1,1). Besar nilai peramalan yang diperoleh dengan menggunakan model GJR-GARCH (1,1) yaitu 974.5213 MW. Nilai ini tidak jauh berbeda dengan nilai actual dari data sebelumnya. Nilai cenderung turun dikarenakan pada periode bulan September terjadi penurunan beban puncak listrik dikarenakan faktor seringnya terjadi pemadaman lampu dan faktor cuaca.

Kata Kunci : ARIMA, *Heterokedasticity*, GJR-GARC

BAB I


PENDAHULUAN

A. Latar Belakang

Energi listrik merupakan suatu kebutuhan dasar yang berperan penting dalam kehidupan masyarakat, dikarenakan dalam setiap peralatan elektronik yang digunakan oleh masyarakat membutuhkan listrik sebagai sumber energi. Komsumsi listrik meningkat seiring dengan pertambahan jumlah pelanggan dan besarnya komsumsi listrik yang digunakan.

Peningkatan kebutuhan listrik tersebut mengharuskan Perusahaan Listrik Negara (PLN) selaku pihak penyedia listrik dapat menyalurkan kebutuhan listrik konsumen agar tercipta stabilitas dalam berbagai bidang. Tenaga listrik tidak dapat disimpan dalam skala besar, oleh sebab itu tenaga listrik harus dapat disediakan pada saat dibutuhkan. Apabila daya yang dihasilkan suatu pembangkit terlalu besar maka akan timbul pemborosan energi yang dapat mengakibatkan kerugian bagi pihak perusahaan listrik. Sedangkan jika daya yang dihasilkan suatu pembangkit lebih kecil dari permintaan maka akan mengakibatkan pemadaman listrik secara bergilir yang mengakibatkan kerugian pada pihak konsumen.

Islam mengajarkan kepada manusia untuk tidak boros terhadap apapun, seperti di tuliskan dalam penggalan ayat QS, Al-A'raf/7: 31 yaitu



Terjemahnya :

“Wahai anak cucu Adam! Pakailah pakaianmu yang bagus pada setiap (memasuki) masjid, makan dan minumlah, tetapi jangan berlebihan. Sungguh, Allah tidak menyukai orang yang berlebih-lebihan.”¹

Ayat di atas menjelaskan mengenai ajakan kepada anak cucu Adam untuk memakai pakaian yang baik dan indah minimal menutup aurat karena tidak menutup aurat itu buruk, dan itu dilakukan setiap memasuki atau berada di masjid, baik masjid dalam artian bangunan maupun dalam pengertian yang luas, yaitu alam bumi ini. Dan makanlah kalian makanan yang halal, enak, bermanfaat lagi bergizi, berdampak baik serta minumlah apa saja yang kamu sukai selama itu tidak memabukkan dan juga tidak mengganggu kesehatan kamu, serta janganlah kamu berlebih-lebihan dalam segala hal, baik dalam beribadah dengan menambah cara atau kadarnya demikian juga dalam makan dan minum atau apa saja, karena sesungguhnya Allah tidak menyukai, yakni tidak melimpahkan rahmat dan ganjaran bagi orang-orang yang berlebih-lebihan dalam hal apapun. Penggalan akhir ayat ini merupakan satu prinsip yang diletakkan agama menyangkut perintah makan dan ,minum secara tidak berlebih-lebihan, yakni tidak melampaui batas, merupakan tuntunan yang harus disesuaikan dengan kondisi setiap orang.²

Itulah sebabnya dalam mengatur tingkat konsumsi listrik yang dibutuhkan oleh konsumen kita harus teliti, karena ketika produksi listrik ini melampaui batas maka akan terjadi kerugian untuk itu perlu diketahui tingkat pemakaian listrik yang digunakan oleh konsumen. Besar energi listrik yang dikonsumsi oleh konsumen dalam rana industri maupun rumah tangga di area

¹ Departemen Agama RI, *Al-Qur'an Terjemahannya dan Asbabun Nuzul*, (Surakarta: PT. Indiva Media Kreasi, 2009), h. 152.

² M.Quraish Shihab, *Tafsir Al-Mishbah: Pesan, Kesan dan Keserasian Al-Qur'an* (Vol 4; Jakarta:Lentera Hati, 2003), h. 87.

Makassar, tercatat secara otomatis dan disajikan dalam bentuk data historis pemakaian listrik harian per 30 menit atau per 1 jamnya selama 24 jam yang dinamakan data beban puncak pemakaian listrik. Menurut (Aulia Khair, 2011) beban puncak energi listrik terjadi ketika tingkat kebutuhan listrik konsumen menanjak ke titik yang paling tinggi pada waktu tertentu, baik dalam rentang waktu jam, hari, minggu, bulan, hingga tahun. Dan untuk wilayah Makassar waktu beban puncak sistem terjadi pada pukul 17.00 sampai dengan pukul 22.00 WITA. Waktu ini adalah waktu dimana semua sistem beban puncak melakukan operasinya dan terjadi peningkatan kebutuhan pemakaian energi listrik.

Pemenuhan energi listrik di Kota Makassar terkadang mengalami masalah, yaitu ditunjukkan dengan adanya pemadaman listrik secara bergilir yang sering dilakukan oleh pihak PLN SULSELBAR. Hal ini mengindikasikan bahwa adanya kekurangan stok energi listrik. Besar pasokan listrik untuk wilayah SULSEL umumnya hanya berkisar 40 MW dan saat ini mengalami peningkatan menjadi 60 MW. Sedangkan selama ini cadangan daya saat beban puncak hanya 140 MW atau sebesar 10%. Padahal idealnya harus lebih dari jumlah tersebut atau sebesar 30%. Sehingga mengakibatkan timbulnyahu persoalan dalam menghadapi kebutuhan daya listrik yang tidak tetap dari waktu ke waktu.³ Untuk itu PLN perlu melakukan perencanaan sistem pengembangan tenaga listrik untuk mengetahui seberalistrik yang harus disalurkan ke konsumen agar daya tersebut dapat tersalurkan pada konsumen dengan tepat sasaran dalam jumlah ukuran yang tepat.

Dalam rangka pemenuhan kebutuhan energi listrik yang memadai, diperlukan manajemen perencanaan operasi sistem yang tepat, salah satunya

³ Fahrizal Syam, " Pemadaman Bergilir Wilayah Makassar", *Tribun Timur*. 16 April 2016. <http://makassar.tribunnews.com> (17 Desember 2016)

yaitu peramalan beban listrik (electrical load forecasting) untuk memberikan informasi bagi pihak PLN agar dapat memperkirakan besarnya permintaan berdasarkan data sebelumnya.

Peramalan atau menduga sesuatu hal yang belum pernah terjadi sebelumnya telah dijelaskan dalam QS Luqman/31: 34 yaitu



Terjemahnya :

“ Sesungguhnya Allah, Hanya pada sisi-Nya sajalah pengetahuan tentang hari Kiamat; dan Dia-lah yang menurunkan hujan, dan mengetahui apa yang ada dalam rahim. dan tiada seorangpun yang dapat mengetahui (dengan pasti) apa yang akan diusahakannya besok, dan tiada seorangpun yang dapat mengetahui di bumi mana dia akan mati. Sesungguhnya Allah Maha mengetahui lagi Maha Mengenal”.⁴

Quraish Shihab dalam tafsir Al-Mishbah mengemukakan bahwa dalam ayat diatas menyatakan : Sesungguhnya Allah, hanya pada sisi-Nya sajalah pengetahuan tentang hari kiamat. Tidak ada mahluk, betapapun tinggi kedudukannya, yang dapat mengetahui masa datangnya, dan Dialah Yang dari saat ke saat menurunkan Hujan dalam berbagai bentuknya, cair atau membeku, dan lokasi dimanapun dia tetapkan, dan Dia pula yang terus menerus mengetahui apa yang ada dalam rahim. Bukan saja jenis kelaminnya tetapi segala sesuatu yang berkaitan dengan janin, termasuk perincian

⁴ Departemen Agama RI, *Al-Qur'an Terjemahannya dan Asbabun Nuzul*, (Surakarta: PT. Indiva Media Kreasi, 2009), h.415.

Kalimat (❁ ❏ 🔱 ⬅️ ➡️ 🌀 🌪️ ☄️ ⚙️ 🔮 🔥 🔵 🔴) yunazzilu al-ghaits/ Dia menurunkan hujan dipahami oleh Ibn Asyur bukan sekadar dalam arti Allah menurunkan hujan, tetapi bahwa Dia mengetahui kapan turunnya hujan. Pendapat ini dapat didiskusikan. Betapapun sampai kini, Badab Meteoroloji masih menggubakan istilah "Prakiraan Cuaca" yakni mereka belum dapat memastikan.

Terasa berbeda antara informasi ayat ini menyangkut pengetahuan-Nya tentang kiamat dan pengetahuan-Nya tentang turunnya hujan serta apa yang ada di dalam rahim. Pengetahuan-Nya tentang kiamat disertai Kata (■◻⊙☆❧↶) indah yang mengandung makna pengkhususan, yakni hanya berada di sisi-Nya, tidak pada siapa pun selain-Nya. Sedangkan yang lainnya tidak secara mutlak demikian sehingga dapat dipahami bahwa keduanya bukanlah termasuk ghaib yang tidak diketahui kecuali oleh Allah.

⁵ M.Quraish Shihab. *Tafsir Al-Mishbah: Pesan, Kesan dan Keserasian Al-Qur'an* (Vol 10; Jakarta:Lentera Hati, 2003), h.163.

Perbedaan ini boleh jadi mengisyaratkan bahwa manusia dapat mengetahui sekelumit tentang hal tersebut bila Allah menyampaikan kepadanya melalui salah satu cara penyampaian, misalnya melalui penelitian ilmiah. Namun manusia dapat mengetahuinya dalam kadar pengetahuan manusia, bukan dalam kadar pengetahuan Allah.

Kata (تَكْسِبُ) taksibu, yaitu apa yang diupayakan oleh manusia yang diduga dapat menghasilkan manfaat atau menampik midarat atau yang diduga demikian, walau kenyataannya tidak demikian.

Berdasarkan tafsir ayat di atas menerangkan bahwa manusia itu tidak dapat mengetahui dengan pasti apa yang akan diusahakannya besok atau yang akan diperolehnya, namun demikian mereka diwajibkan berusaha. Maksud dari kata berusaha ini yaitu menerka, memprediksi atau meramalkan sesuatu yang akan terjadi berdasarkan dengan apa yang pernah terjadi pada masa lampau sesuai dengan data historisnya. Metode peramalan ini dapat digunakan untuk melakukan perencanaan operasi sistem yang baik dalam bidang apapun termasuk dalam bidang perencanaan pemenuhan kebutuhan listrik khususnya pada bidang peramalan beban puncak listrik harian jangka pendek.

Tingkat konsumsi listrik yang digunakan oleh konsumen memiliki tingkat yang berbeda-beda tergantung pada tingkat kebutuhan dan waktu penggunaan listrik. Tingkat konsumsi listrik pada hari-hari kerja tentunya akan berbeda dengan tingkat konsumsi listrik pada hari-hari libur. Biasanya konsumen lebih banyak menggunakan listrik dalam waktu kerja dikarenakan pada hari kerja semua sistem beroperasi. Sedangkan pada waktu libur ada beberapa sistem yang tidak beroperasi. Dan hal ini yang merupakan penyebab terjadinya perbedaan tingkat konsumsi listrik dalam kurung waktu harian.

Salah satu metode peramalan yang dapat digunakan untuk meramalkan beban puncak listrik yang memiliki nilai varians yang tidak konstan adalah model *Autoregressive Conditional Heteroscedasticity* (ARCH) atau *Generalized Autoregressive conditional heteroscedasticity* (GARCH).

Kedua model ini mengasumsikan bahwa error yang positif dan error yang negative akan memberi pengaruh yang sama terhadap pergerakan variansnya. Namun pada faktanya, asumsi ini seringkali dilanggar, karena umumnya data runtun waktu akan menunjukkan fenomena ketidaksimetrisan antara nilai error positif dan error negative terhadap pola variansnya. Dalam kasus dunia kelistrikan kondisi ini juga sering terjadi misalnya kenaikan tarif listrik akan memberikan efek terhadap tingkat konsumsi listrik, selain itu ketika terjadi permasalahan dalam teknis PLN atau mengalami kerusakan sistem maka akan berakibat berkurangnya tingkat penggunaan listrik dan mengakibatkan perbedaan konsumsi listrik dan merupakan efek negative dari data tersebut sehingga model peramalan *Glosten, Jagannathan, Runkle Generalized Autoregressive Conditional Heteroskedasticity* (GJR-GARCH) cocok digunakan untuk melakukan peramalan beban puncak listrik. Model ini pertama kali diperkenalkan oleh Glosten, Jagannathan dan Runkle pada tahun 1993.

Penelitian sebelumnya yang dilakukan oleh Bagus Dwiantoro (2012) menjelaskan mengenai peramalan beban puncak listrik jangka pendek menggunakan metode *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH) dan berkesimpulan bahwa variansi beban listrik yang tidak homogen (heteroskedastisitas) karena pola konsumsi listrik berbeda-beda menjadikan model GARCH baik digunakan dalam peramalan.

Hal ini dikarenakan model ini tidak menganggap heteroskedastisitas sebagai masalah, melainkan memanfaatkan kondisi tersebut untuk membuat model GARCH yang terdiri dari mean model dan variance residual model. Selain dalam bidang kelistrikan, metode GJR-GARCH juga digunakan oleh Komang Dharmawan (2015) dalam penelitiannya itu menjelaskan mengenai estimasi nilai Avar menggunakan model GJR-GARCH dan model GARCH dan diperoleh hasil bahwa nilai Var dan Avar dengan pendekatan model GJR-GARCH memberikan agresifitas yang lebih tinggi jika dibandingkan dengan model GARCH. Untuk itu peneliti tertarik ingin meramalkan beban puncak listrik dengan menggunakan Model GJR-GARCH.

B. Rumusan Masalah

Adapun rumusan masalah dalam penelitian ini yaitu

1. Bagaimana model persamaan peramalan beban puncak energi listrik dengan menggunakan metode GJR-GARCH ?
2. Bagaimana hasil peramalan beban puncak energi listrik dengan menggunakan metode GJR-GARCH ?

C. Tujuan

Adapun tujuan dari penelitian ini yaitu

1. Mengetahui model persamaan peramalan beban puncak energi listrik dengan menggunakan metode GJR-GARCH
2. Mengetahui hasil peramalan beban puncak energi listrik dengan menggunakan metode GJR-GARCH

D. Batasan Masalah

Berdasarkan pemaparan diatas peniliti membatasi pokok permasalahan yaitu

1. Penelitian ini berfokus pada data historis beban puncak energi listrik jangka pendek.
2. Penelitian ini hanya menggunakan data historis beban puncak untuk wilayah Makassar
3. Hasil peramalan untuk periode selanjutnya hanya sampai pada periode 10

E. Manfaat Penelitian

Adapun manfaat yang diperoleh dari penelitian ini antara lain sebagai berikut :

1. Bagi peneliti: Sebagai bahan pembelajaran dan menambahkan pengetahuan terutama dibidang statistik khususnya dalam melakukan peramalan.
2. Bagi pengembangan ilmu pengetahuan: Agar dapat dijadikan sebagai bahan studi kedepannya bagi pembaca dan acuan bagi mahasiswa serta dapat memberikan bahan referensi bagi pihak perpustakaan sebagai bahan bacaan yang dapat menambah ilmu pengetahuan bagi pembaca dalam hal ini mahasiswa.
3. Bagi Perusahaan : Dapat dijadikan sebagai pedoman bagi PT PLN (Persero) dalam melakukan perencanaan operasi terutama pada perencanaan peramalan beban puncak energi listrik .

F. Sistematika Penulisan

Sistematika penulisan pada tugas akhir ini adalah sebagai berikut

BAB I : PENDAHULUAN

Pada Bab ini membahas mengenai Latar Belakang Masalah, rumusan masalah, tujuan penelitian, manfaat penelitian, batasan masalah dan sistematika penulisan.

BAB II : TINJAUAN PUSTAKA

Pada Bab ini membahas mengenai teori-teori yang digunakan untuk menunjang dan menyelesaikan masalah yang berhubungan dengan peramalan beban puncak energi listrik dengan menggunakan metode ARIMA GJR-GARCH

BAB III : METODE PENELITIAN

Pada bab ini membahas mengenai jenis penelitian, jenis data dan sumber data penelitian, Prosedur Penelitian

BAB IV: PEMBAHASAN DAN HASIL

Pada bab ini membahas mengenai penentuan model peramalan dengan menggunakan ARIMA GJR-GARCH serta menganalisis hasil peramalan yang diperoleh.

BAB V: KESIMPULAN DAN HASIL

Pada bab ini membahas mengenai kesimpulan dari hasil penelitian dan saran-saran untuk penelitian selanjutnya.

DAFTAR PUSTAKA

UNIVERSITAS ISLAM NEGERI
ALAUDDIN
M A K A S S A R

BAB II

TINJAUAN PUSTAKA

A. Peramalan

Peramalan merupakan suatu proses memperkirakan sesuatu secara sistematis tentang kejadian di masa depan dengan menggunakan informasi dari masa lalu dan sekarang agar kesalahannya (selisih antara apa yang terjadi dengan hasil perkiraan) dapat diperkecil.⁶ Peramalan merupakan suatu langkah awal dalam melakukan langkah pengambilan keputusan dan perencanaan. Dengan dasar peramalan ini, maka akan didapatkan data untuk sekarang ataupun masa depan melalui pengujian dengan data dimasa lalu. Meskipun peramalan pada awalnya hanya merupakan suatu perkiraan, namun karena menggunakan teknik peramalan tertentu baik formal maupun informal perkiraan ini menjadi perkiraan yang tidak biasa dan dapat dipertanggung jawabkan melalui berbagai perhitungan dan data yang kemudian menjadi informasi yang berguna.⁷

Ada dua jenis model peramalan yang utama, yaitu model time series dan model kausal. Untuk model time series pendugaan masa depan dilakukan berdasarkan nilai pada masa lalu dari suatu variabel dan kesalahan masa lalu. Tujuannya model ini yaitu untuk menemukan pola data time series dalam data historis dan mengekstrapolasi ke masa depan. Sedangkan untuk model kausal

⁶ Akhmat Tohir, “Analisis Peramalan Penjualan Minyak Sawit Kasar Atau Crude Oil (CPO) Pada PT. Kharisma Pemasaran Bersama (KPB)”, *Skripsi* (UIN Syarif Hidayatullah, 2012), h. 12

⁷ Amin Syukron, “ *Pengantar Teknik Industri* “, (Yogyakarta: Graha Ilmu, 2014), h.71

diasumsikan bahwa factor yang diramalkan menunjukkan hubungan sebab akibat dengan menggunakan satu variable atau lebih.⁸

Menurut Magdalena berdasarkan sifatnya, peramalan dapat dibagi menjadi dua macam yaitu,⁹

a. Peramalan Kualitatif

Peramalan ini merupakan peramalan yang berdasarkan atas data kualitatif pada masa lalu. Hasil dari peramalan ini sangat tergantung pada hasil pemikiran peneliti yang berdasarkan sifat intuisi, judgment atau pendapat dan pengetahuan serta pengalaman dari penyusunnya.

b. Peramalan Kuantitatif

Peramalan ini merupakan peramalan yang berdasarkan data kuantitatif pada masa lalu. Hasil peramalan bergantung pada metode yang digunakan untuk melakukan peramalan. Metode yang baik adalah metode yang menghasilkan error yang kecil. Peramalan kuantitatif hanya dapat digunakan apabila terdapat kondisi sebagai berikut:

- 1) Tersedianya informasi tentang masa lalu.
- 2) Adanya informasi yang dapat dikuantifikasikan dalam bentuk data numerik.
- 3) Dapat diasumsikan bahwa pola yang lalu akan berkelanjutan pada masa yang akan datang

⁸ Muthia, dkk., *Penerapan Metode Trend Moment Dalam Forecast Penjualan Motor Yamaha Di PT. Hasjrat Abadi* (2013), h..6

⁹ Magdalena Lumbantobing, *Peramalan Nilai Penjualan Energi Listrik di PT. PLN (PERSERO) Cabang Binjai*, (Medan: Universitas Suamtera Utara, 2008), h.11

B. Time Series

Analisis deret waktu diperkenalkan pada tahun 1970 oleh George E.P. Box dan Gwilym M.Jenkins melalui bukunya yang berjudul “ *Time Series Analysis : Forecasting and Control* “. Sejak saat itu deret waktu banyak dikembangkan.¹⁰ Deret waktu (*Time Series*) adalah serangkaian nilai pengamatan (*observasi*) yang diambil selama kurun waktu tertentu, pada umumnya dalam interval-interval yang sama panjang. Beberapa contoh deret waktu adalah produksi total tahunan besi baja di Amerika Serikat untuk kurun waktu beberapa tahun, harga penutupan harian sebuah saham di pasar modal untuk kurun waktu satu bulan, suhu udara per jam diberitakan oleh badan meteorologi sebuah kota selama kurun waktu sehari, dan penjualan total bulanan sebuah pasar swalayan selama kurun waktu satu tahun.¹¹

Dalam proses peramalan harus memperhatikan dan mempelajari terlebih dahulu sifat dan perkembangan nilai dari variabel yang lalu agar dapat meramalkan nilai variabel waktu yang akan datang. Nilai dari suatu variabel dapat diramal ketika nilai sifat dari variabel tersebut dapat diketahui pada kurun waktu yang lalu dan sekarang, sebagai bahan pembelajaran untuk mengetahui perkembangan historis dari suatu variabel, biasanya urutan nilai-nilai variabel itu diamati menurut waktu. Urutan waktu seperti ini dinamakan runtun waktu adalah serangkaian pengamatan terhadap suatu peristiwa, kejadian, gejala atau variabel yang diambil dari waktu ke waktu, dicatat secara teliti menurut urutan-urutan waktu terjadinya dan kemudian disusun data historis. Adapun beberapa waktu yang digunakan untuk meramalkan yaitu berupa harian, mingguan, bulan, tahun dan sebagainya.

¹⁰ Aswi dan Sukarna, *Analisis Deret Waktu*, (Makassar: Andira Publisher, 2006), h.5

¹¹ Murray dan Larry, *Statistik Edisi Ketiga*, (Jakarta: Erlangga, 2004), h.352

Secara matematis, deret waktu didefinisikan oleh nilai-nilai Z_1, Z_2, \dots dari suatu variabel Z (Suhu udara, harga penutupan saham, dan sebagainya) untuk titik-titik waktu t_1, t_2, \dots . Dengan demikian, Z merupakan sebuah fungsi dari t dan disimbolkan dengan $Z = f(t)$.¹²

Menurut Aswi dan Sukarna suatu pengamatan memiliki model deret waktu jika memenuhi dua hal berikut :¹³

1. Interval waktu antar indeks waktu t dapat dinyatakan dalam suatu susunan waktu yang sama dan identik
2. Adanya ketergantungan antara pengamatan Z_t , dengan Z_{t+k} yang dipisahkan oleh jarak dan waktu berupa kelipatan Δ_t sebanyak k kali (dinyatakan sebagai lag k)

Menurut Murray dan Larry pergerakan khas deret waktu dapat diklasifikasikan kedalam empat tipe yang sering kali disebut juga sebagai komponen-komponen deret waktu antara lain :¹⁴

1. Pergerakan Jangka Panjang atau Sekuler (*Tren*)

Komponen ini menggambarkan arah pergerakan umum sebuah deret waktu jangka panjang. Pergerakan sekuler atau biasa juga disebut variasi sekuler atau tren sekuler yang direpresentasikan oleh garis putus-putus, yang disebut juga sebagai garis tren. Dalam sebagian kasus, pergerakan ini direpresentasikan secara lebih baik oleh kurva tren ketimbang sebuah garis lurus.

2. Pergerakan Musiman atau Variasi Musiman (*Seasonality*)

¹² Dewi Nur Samsiah, *Analisis Data Runtun Waktu Menggunakan Model Arima (P,D,Q)*, (Yogyakarta: UIN Sunan Kalijaga, 2008) h. 11-12

¹³ Aswi & Sukarna, *Analisis Deret Waktu*, (Makassar: Andira Publisher, 2006). h.6

¹⁴ Murray dan Larry, *Statistik Edisi Ketiga*, (Jakarta: Erlangga, 2004), h.353

Komponen ini merepresentasikan pola-pola yang identik atau nyaris identik, terlihat dalam pergerakan sebuah deret waktu untuk interval-interval waktu satu bulanan atau triwulan selama beberapa tahun berturut-turut. Pergerakan semacam ini ditimbulkan oleh peristiwa-peristiwa berkala, misalnya terjadi sekali dalam setahun, seperti lonjakan tajam angka penjualan yang dialami oleh toserba sebelum natal.

3. Pergerakan Siklik atau Variasi Siklik (*Cycle*)

Komponen ini merepresentasikan pergerakan fluktuasi (osilasi atau ayunan) jangka panjang disekitar garis atau kurva tren. Siklus ini dapat bersifat periodik atau nonperiodik, yaitu variasi nilai yang diperlihatkannya boleh jadi mengikuti atau tidak mengikuti suatu pola tertentu dan untuk interval-interval waktu yang tidak tetap. Salah satu contoh penting dalam pergerakan siklik adalah apa yang disebut siklus bisnis, yang menggambarkan runtutan masa kesejahteraan ekonomi, resesi, depresi, dan pemulihan secara bergantian dan berulang-ulang.

4. Acak (*Irregular*)

Komponen ini menggambarkan variasi-variasi sporadis pada deret waktu yang disebabkan oleh berbagai peristiwa kebetulan atau acak, seperti misalnya banjir, pemogokan buruh, dan gejolak politik. Meskipun biasanya kejadian-kejadian ini dianggap hanya menimbulkan variasi-variasi sementara yang tidak berlangsung lama, diketahui pula bahwa intensitas suatu kejadian bisa saja begitu hebat sehingga memunculkan suatu siklus atau pergerakan baru.

C. Stokastik dan Stasioneritas

Jika Z_t , adalah pengamatan pada waktu t dan Z_t adalah peubah acak (random variable), rangkaian peubah acak Z_t adalah $\{Z_1, Z_2, \dots, Z_t\}$ yang disebut sebagai proses stokastik. Proses stokastik merupakan suatu proses yang

menghasilkan rangkaian nilai-nilai peubah acak yang menggambarkan perilaku data pada berbagai kondisi. Setiap data deret waktu merupakan suatu data dari hasil proses stokastik. Proses stokastik dapat bersifat stasioner dan menghasilkan data deret waktu yang bersifat stasioner. Sebaliknya, proses stokastik dapat bersifat tidak stasioner dan menghasilkan data deret waktu yang juga tidak stasioner.¹⁵

Ciri-ciri model analisis deret waktu adalah dengan mengasumsikan bahwa data dalam keadaan stasioner. Deret dikatakan stasioner jika tidak ada perubahan variansi. Dengan kata lain, deret waktu yang stasioner jika tidak ada perubahan kecenderungan dalam rata-rata dan perubahan variansi atau kata lain deret waktu yang stasioner adalah nilai deret waktu yang relatif tidak terjadi kenaikan ataupun penurunan nilai secara tajam pada data (fluktuasi data berada pada sekitar nilai rata-rata yang konstan).

Kondisi stasioner terdiri atas dua hal, yaitu stasioner dalam rata-rata dan stasioner dalam variansi. Misalkan suatu pengamatan $Z_1, Z_2, Z_3, \dots, Z_n$ sebagai suatu proses stokastik, peubah acak $Z_{t1}, Z_{t2}, Z_{t3}, \dots, Z_{tn}$ dikatakan stasioner orde ke- m apabila

$$F(Z_{t1}, Z_{t2}, Z_{t3}, \dots, Z_{tn}) = F(Z_{t1+k}, Z_{t2+k}, Z_{t3+k}, \dots, Z_{tn+k}) \quad (2.1)$$

Dimana $F(.)$ merupakan simbol dari suatu fungsi distribusi. Apabila persamaan (2.1) terpenuhi untuk $m = 1, 2, 3, \dots, n$ maka kondisi tersebut dinamakan stasioner kuat (*strictly stationary*). Box dan Jenkins (1976) menjelaskan bahwa pada deret waktu yang bersifat stasioner kuat, waktu pengamatan tidak berpengaruh terhadap rata-rata μ , variansi σ^2 , dan kovariansi γ_k . Ini berarti bahwa deret Z_t akan berfluktuasi di sekitar μ dan

¹⁵ Bambang Juanda dan Junaidi, *Ekonometrika Deret Waktu Teori dan Aplikasinya*, (Bogor: IPB Press, 2012), h.20

variansi σ^2 yang tetap, dan dapat dikatakan bahwa deret Z_t stasioner dalam μ dan σ^2 .¹⁶

Dengan perkataan lain, agar suatu series dapat disebut stasioner maka ia harus memiliki sifat seperti berikut :

$$E(Z_t) = \mu \quad (2.2)$$

$$E[Z_t - \mu]^2 = \sigma^2 \quad (2.3)$$

$$E[Z_{t_1} - \mu][Z_{t_2} - \mu] = \gamma_{t_2-t_1} ; \forall t_1, t_2 \quad (2.4)$$

Persamaan (2.2) mengatakan bahwa momen pertama yakni nilai rata-rata (*ekspektasi*) adalah konstan. Series juga dikatakan stasioner jika memiliki varians yang konstan untuk persamaan (2.3) dan autokovarians yang nilainya hanya terikat dari jarak dan waktu. Konsep lain yang berkaitan dengan stasioneritas adalah proses *white noise*. *White noise* atau yang sering disebut proses *Gaussian* adalah kondisi stasioner yang lebih ketat dimana nilai dari autokovarians harus bernilai nol. Dengan kata lain, tidak ada hubungan antara realisasi data pada periode t_1 dengan t_2 untuk sembarang periode t_1 dan t_2 .¹⁷

1. Stasioner dan Non-Stasioner dalam mean

Untuk memeriksa kestasioneran data dapat digunakan diagram deret waktu (*time series plot*) yaitu diagram pencar antara nilai peubah Z_t pada waktu t . Jika diagram deret waktu berfluktuasi disekitar garis yang sejajar sumbu waktu (t) maka dapat dikatakan deret (*series*) stasioner dalam rata-rata. Bila kondisi stasioner dalam rata-rata tidak terpenuhi maka diperlukan suatu proses pembedaan (*differencing*).¹⁸

¹⁶ Aswi dan Sukarna, *Analisis Deret Waktu*, (Makassar: Andira Publisher, 2006), h.7-8

¹⁷ Doddy Ariefianto, *Ekonometrika esensi dan aplikasi dengan menggunakan Eviews*, (Jakarta: Erlangga, 2012), h.85

¹⁸ Aswi dan Sukarna, *Analisis Deret Waktu*, (Makassar: Andira Publisher, 2006), h.7-8

Tujuan menghitung perbedaan adalah untuk mencapai stasioneritas. Notasi yang digunakan adalah operator shift mundur (*backshift operator*) B , yang penggunaannya sebagai berikut :

$$BZ_t = Z_{t-1} \quad (2.5)$$

Dengan

Z_t = nilai variabel Z pada periode t

Z_{t-1} = nilai variabel Z pada periode $t - 1$

B = *backshift operator*

Notasi B yang berpasangan pada Z mempunyai pengaruh menggeser data satu waktu belakang. Sebagai contoh, jika suatu data *time series nonstasioner*, maka data tersebut dapat dibuat mendekati stasioner dengan melakukan *differencing* orde pertama dari data. Rumus untuk *differencing* orde pertama, yaitu

$$Z'_t = Z_t - Z_{t-1} \quad (2.6)$$

Dengan Z'_t = nilai variabel Z pada waktu t setelah *differencing*.

Dengan menggunakan *backshift operator*, persamaan (2.6) dapat ditulis menjadi

$$Z'_t = Z_t - BZ_t \quad (2.7)$$

Atau

$$Z'_t = (1 - B)Z_t \quad (2.8)$$

Differencing pertama pada persamaan (2.8) dinyatakan oleh $(1 - B)$

Differencing orde kedua, yaitu *differencing* pertama dari *differencing* sebelumnya.

Jika *differencing* orde kedua harus di hitung, maka

$$\begin{aligned} Z''_t &= Z'_t - Z'_{t-1} \\ &= (Z_t - Z_{t-1}) - (Z_{t-1} - Z_{t-2}) \\ &= Z_t - 2Z_{t-1} + Z_{t-2} \\ &= (1 - 2B + B^2)Z_t \\ &= (1 - B)^2 Z_t \end{aligned} \quad (2.9)$$

Differencing orde kedua pada persamaan (2.9) dinotasikan oleh $(1 - B)^2$. Secara umum jika terdapat *differencing* orde ke- d untuk mencapai stasioneritas, maka dapat dinotasikan dengan

$$(1 - B)^d, \quad d \geq 1 \quad (2.10)$$

Sedangkan untuk menstasionerkan data dalam varians dapat dilakukan dengan cara transformasi. Pendekatan utama untuk memperoleh stasioneritas dalam varians adalah dengan melakukan transformasi logaritma atau transformasi kemampuan data. Jika data telah stasioner setelah dilakukan transformasi, maka data dapat dilanjutkan untuk tahap berikutnya.¹⁹

2. Stasioner dan Non-Stasioner dalam variansi

Sebuah data time series dapat dikatakan stasioner dalam varians jika struktur dari waktu ke waktu mengalami fluktuasi data yang cenderung konstan atau tetap dan tidak berubah-ubah. Untuk melihat fluktuasi data tersebut dapat menggunakan plot time series. Apabila terjadi ketidakstasioneran dalam variansi, maka dapat dilakukan perubahan untuk menstabilkan variansi dengan cara melakukan transformasi pada parameteranya.

Misalkan $T(Z_t)$ adalah transformasi dari Z_t dan untuk menstabilkan variansi. Kita dapat menggunakan transformasi kuasa.²⁰

$$T(Z_t) = \frac{Z_t^\lambda - 1}{\lambda}, \quad (2.11)$$

Dengan λ disebut parameter transformasi

Berapa nilai λ yang umum digunakan sebagai berikut :

Tabel 2.1 Nilai λ yang digunakan untuk transformasi

¹⁹ Astin Nurhayati, *Peramalan Jumlah Penumpang Pada Pt. Angkasa Pura I (Persero) Kantor Cabang Bandar Udara Internasional Adisutjipto Yogyakarta Dengan Metode Winter's Exponential Smoothing Dan Seasonal Arima*, (2010), h.14-15

²⁰ Dewi Nur Samsiah.2008. *Analisis Data Runtun Waktu Menggunakan Model Arima (P,D,Q)*. Hlm 14-16

λ	Bentuk transformasi
-1	$\frac{1}{Z_t}$
-0,5	$\frac{1}{\sqrt{Z_t}}$
0	$\ln(Z_t)$
0,5	$\sqrt{Z_t}$
1	Z_t (tidak ditransformasikan)

Sumber : Dewi Nur Samsiah “ Analisis Data Runtun Waktu Model Arima”

D. ARIMA Box-Jenkins

Model ARIMA terdiri dari dua aspek, yaitu aspek *Autoregressive* dan *Moving Average* (rata-rata bergerak). Secara umum, model ARIMA dapat dituliskan dengan notasi ARIMA (p, d, q), dimana p menyatakan orde dari proses *autoregressive* (AR), d menyatakan pembedaan (*differencing*), dan q menyatakan orde dari proses *moving average* (MA). Dasar dari pendekatan Box-Jenkins terdiri dari empat tahap yaitu identifikasi; penaksiran (*estimation*) parameter, pemeriksaan diagnostik (*diagnostic checking*) dan peramalan (*forecasting*).²¹

1. Autoregressive (AR)

Model *autoregressive* dengan ordo AR (p) atau model ARIMA (p,0,0) dinyatakan sebagai berikut

$$Z_t = \mu + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + \varepsilon_t \quad (2.12)$$

Dimana :

²¹ Aswi & Sukarna, *Analisis Deret Waktu*, (Makassar: Andira Publisher, 2006), h.21

μ	= konstanta
Z_t	= variabel terikat
$\phi_1, \phi_2, \dots, \phi_p$	= parameter <i>autoregressive</i>
ε_t	= nilai error pada periode t
$Z_{t-1}, Z_{t-2}, \dots, Z_{t-p}$	= variabel bebas

Variabel bebas merupakan deretan nilai dari variabel yang sama dalam beberapa periode sampai pada t terakhir. Sedangkan ε_t merupakan nilai kesalahan yang menggambarkan gangguan acak yang tidak dapat dijelaskan oleh model.

2. *Moving Average* (MA)

Model lain dari model ARIMA adalah *moving average* yang dinotasikan dalam MA (q) atau ARIMA (0,0,q) yang ditulis dalam persamaan berikut :

$$Z_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (2.13)$$

Dimana :

μ	= suatu konstanta
Z_t	= variabel dependent
$\theta_1, \theta_2, \dots, \theta_q$	= parameter <i>moving average</i>
$\varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-q}$	= selisih nilai aktual dengan nilai peramalan

3. *Autoregressive Moving Average* (ARMA)

Dari model *autoregressive* (AR) dan *moving average* (MA) dapat dibentuk model baru yang merupakan gabungan dari kedua model tersebut, yaitu ARMA (*Autoregressive Moving Average*) dengan orde ARMA (p,q). adapun bentuk persamaannya adalah sebagai berikut :

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (2.14)$$

4. *Autoregressive Integrated Moving Average* (ARIMA)

Dari model autoregressive (AR) dan Moving Average (MA) dapat dibentuk model baru yang merupakan gabungan dari keduanya, yaitu ARIMA (autoregressive integrated moving average) dengan orde (p,d,q). bentuk umum dari persamaan ARIMA adalah sebagai berikut :²²

$$\phi_p(B)(1-B)^d\dot{Z}_t = \theta_q(B)\varepsilon_t$$

ARIMA (Autoregressive Integrated Moving Average) merupakan tipe model peramalan dalam bidang keuangan dan menyatakan bahwa ARIMA tidak mampu memodelkan time series yang non-linier. Aspek-aspek AR dan MA dari model ARIMA hanya berkenaan dengan deret berkala yang stasioner. ²³

E. ACF (Autocorrelation Function) dan PACF (Partial Autocorrelation Function)

1. Autocorrelation Function (ACF)

ACF atau fungsi autokorelasi merupakan suatu hubungan linear pada data time series antara Z_t dengan Z_{t+k} yang dipisahkan oleh waktu k. ACF ini dapat digunakan untuk mengidentifikasi model time series dan melihat kestasioneran data dalam mean. Bentuk fungsi autokorelasi adalah

$$\rho_k = \frac{\text{cov}(Z_t, Z_{t+k})}{\sqrt{\text{var}(Z_t)}\sqrt{\text{var}(Z_{t+k})}} = \frac{\gamma_k}{\gamma_0} \quad (2.16)$$

Dan kovarians antara Z_t dan Z_{t+k} adalah

$$\gamma_k = \text{cov}(Z_t, Z_{t+k}) = E(Z_t - \mu)(Z_{t+k} - \mu) \quad (2.17)$$

Dengan :

$$\text{Var}(Z_t) = \text{Var}(Z_{t+k}) = \gamma_0 \quad (2.18)$$

$$\gamma_k = \text{fungsi Autocovarians}$$

²² Bagus Dwiantoro, “Peramalan Beban Listrik Jangka Pendek Berdasarkan Data Historis Menggunakan Metode Generalized Autoregressive Conditional Heteroskedasticity (GARCH). Universitas Indonesia”, *Skripsi* (Depok: Universitas Jakarta, 2012), h.11

²³ Susansti, “Analisis Model Threshold Garch Dan Model Exponential Garch Pada Peramalan Ihsg”, *Skripsi* (Semarang: Universitas Negeri Semarang, 2015), h.12

$\rho_k = \text{Autocorrelation Function (ACF)}$

Sedang fungsi autokorelasi yang dihitung berdasarkan sampel data dapat dirumuskan sebagai berikut :

$$\hat{\rho}_k = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2} \quad \text{untuk } k = 0, 1, 2 \quad (2.19)$$

2. Partial autocorrelation function (PACF)

Fungsi autokorelasi parsial merupakan korelasi antara Z_t dengan Z_{t+k} setelah Z_t dijelaskan oleh $Z_{t-1}, Z_{t-2}, \dots, Z_{t-k+1}$. fungsi autokorelasi parsial dirumuskan sebagai berikut :

$$\rho_k = \frac{\text{Cov}[(Z_t - \hat{Z}_t), (Z_{t+k} - \hat{Z}_{t+k})]}{\sqrt{\text{Var}(Z_t - \hat{Z}_t)} \sqrt{\text{Var}(Z_{t+k} - \hat{Z}_{t+k})}} \quad (2.20)$$

Dalam pengamatan time series, sampel PACF dinotasikan dengan ϕ_{kk} dengan perhitungan :

$$\phi_{k+1,k+1} = \frac{\rho_{k+1} - \sum_{j=1}^k \phi_{kj} \rho_{k+1-j}}{1 - \sum_{j=1}^k \phi_{kj} \rho_j} \quad (2.21)$$

dan

$$\hat{\phi}_{k+1,j} = \phi_{kj} - \phi_{k+1,k+1} \phi_{k,k+1-j}, j = 1, 2, \dots, k^{24} \quad (2.22)$$

F. Metode Maximum Likelihood

Maximum likelihood method (metode kemungkinan maksimum) adalah teknik yang sangat sering digunakan untuk menaksirkan parameter distribusi data. Berikut penjelasan tentang maximum likelihood method pada persamaan regresi.

$$Y_t = \beta_0 + \beta_1 X_t + \varepsilon_t, \varepsilon_t \sim N(0, \sigma^2) \quad (2.23)$$

$$Y_t \sim N(0, \sigma^2), \mu_t = E(Y_t) = E(\beta_0 + \beta_1 X_t + \varepsilon_t) \quad (2.24)$$

$$\mu_t = \beta_0 + \beta_1 X_t \quad (2.25)$$

$$\sigma^2 = \text{Var}(Y_t)$$

²⁴ Ardita Sukma, *Perbandingan Metode Time Series Regression Dan Arimax Pada Pemodelan Data Penjualan Pakaian Di Boyolali*, (Surabaya, 2010), h. 25

Maka fungsi densitas probabilitas residual yang berdistribusi normal untuk setiap eksperimen adalah :

$$f_{Y_1}(\varepsilon_1) = \frac{1}{\sqrt{2\pi\sigma_1^2}} \exp\left(-\frac{(Y_1 - \mu_1)^2}{2\sigma_1^2}\right) \quad (2.26)$$

$$= \frac{1}{\sqrt{2\pi\sigma_1^2}} \exp\left(-\frac{(Y_1 - (\beta_0 + \beta_1 X_1))^2}{2\sigma_1^2}\right)$$

$$f_{Y_2}(\varepsilon_2) = \frac{1}{\sqrt{2\pi\sigma_2^2}} \exp\left(-\frac{(Y_2 - \mu_2)^2}{2\sigma_2^2}\right) \quad (2.27)$$

$$= \frac{1}{\sqrt{2\pi\sigma_2^2}} \exp\left(-\frac{(Y_2 - (\beta_0 + \beta_1 X_2))^2}{2\sigma_2^2}\right)$$

⋮

$$f_{Y_n}(\varepsilon_n) = \frac{1}{\sqrt{2\pi\sigma_n^2}} \exp\left(-\frac{(Y_n - \mu_n)^2}{2\sigma_n^2}\right) \quad (2.28)$$

$$= \frac{1}{\sqrt{2\pi\sigma_n^2}} \exp\left(-\frac{(Y_n - (\beta_0 + \beta_1 X_n))^2}{2\sigma_n^2}\right)$$

Karena $Y_t = \beta_0 + \beta_1 X_t + \varepsilon_t$ dan $\varepsilon_t = Y_t - (\beta_0 + \beta_1 X_t)$ maka fungsi densitas (2.28) menjadi

$$f(\varepsilon_n) = \frac{1}{\sqrt{2\pi\sigma_n^2}} \exp\left(-\frac{\varepsilon_n^2}{2\sigma_n^2}\right) \quad (2.29)$$

Dan densitas keseluruhan untuk n observasi adalah :

$$f(\varepsilon_n) = \prod_{t=1}^n \frac{1}{\sqrt{2\pi\sigma_t^2}} \exp\left(-\frac{\varepsilon_t^2}{2\sigma_t^2}\right) \quad (2.30)$$

Maka fungsi Likelihood-nya adalah :

$$L(\varepsilon_n) = \prod_{t=1}^n \frac{1}{\sqrt{2\pi\sigma_t^2}} \exp\left(-\frac{\varepsilon_t^2}{2\sigma_t^2}\right) \quad (2.31)$$

$$L(\varepsilon_n) = \sum_{t=1}^n \frac{1}{\sqrt{2\pi\sigma_t^2}} \exp\left(-\frac{\varepsilon_t^2}{2\sigma_t^2}\right) \quad (2.32)$$

Membuat transformasi fungsi tersebut dalam bentuk \ln

$$\ln L(\varepsilon_n) = \ln \left(\sum_{t=1}^n \frac{1}{\sqrt{2\pi\sigma_t^2}} \exp \left(-\frac{\varepsilon_t^2}{2\sigma_t^2} \right) \right) \quad (2.33)$$

$$\ln L(\varepsilon_n) = \ln \left(\sum_{t=1}^n (2\pi\sigma_t^2)^{-\frac{1}{2}} \exp \left(-\frac{\varepsilon_t^2}{2\sigma_t^2} \right) \right) \quad (2.34)$$

$$\ln L(\varepsilon_n) = -\frac{n}{2} \ln (2\pi) \left(\sum_{t=1}^n (\sigma_t^2)^{-\frac{1}{2}} \exp \left(-\frac{\varepsilon_t^2}{\sigma_t^2} \right) \right) \quad (2.35)$$

Dengan mensubstitusi nilai $\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2$ dan $\varepsilon_t = Y_t - (\beta_0 + \beta_1 X_t)$ maka persamaan (2.35) menjadi

$$\ln L(\varepsilon_n) = -\frac{n}{2} \ln (2\pi) \left(\sum_{t=1}^n (\alpha_0 + \alpha_1 \varepsilon_{t-1}^2)^{-\frac{1}{2}} \exp \left(-\frac{Y_t - (\beta_0 + \beta_1 X_t)}{\alpha_0 + \alpha_1 \varepsilon_{t-1}^2} \right) \right) \quad (2.36)$$

Untuk mendapatkan nilai parameter-parameter $\alpha_0, \alpha_1, \beta_0$ dan β_1 , maka persamaan (2.36) diturunkan terhadap parameter-parameter tersebut satu persatu seperti berikut :

$$\frac{\partial(\ln L)}{\partial \alpha_0} = -\frac{1}{2} \left(\sum_{t=1}^n \ln(\alpha_0 + \alpha_1 \varepsilon_{t-1}^2) + \left(\frac{Y_t - (\beta_0 + \beta_1 X_t)}{\alpha_0 + \alpha_1 \varepsilon_{t-1}^2} \right) \right) = 0 \quad (2.37)$$

$$\frac{\partial(\ln L)}{\partial \alpha_1} = -\frac{1}{2} \left(\sum_{t=1}^n \ln(\alpha_0 + \alpha_1 \varepsilon_{t-1}^2) + \left(\frac{Y_t - (\beta_0 + \beta_1 X_t)}{\alpha_0 + \alpha_1 \varepsilon_{t-1}^2} \right) \right) = 0 \quad (2.38)$$

G. Uji Signifikansi Parameter

Model ARIMA yang baik dapat menggambarkan suatu kejadian model yang dapat menunjukkan bahwa penaksiran parameternya signifikan berbeda dengan nol. Secara umum, misalkan θ adalah suatu parameter dari model ARIMA dan $\hat{\theta}$ adalah nilai taksiran dari parameter tersebut, serta SE adalah standar error dari nilai taksiran $\hat{\theta}$, maka uji kesignifikan parameter dapat dilakukan dengan langkah sebagai berikut

Hipotesis

$$H_0 : \hat{\theta} = 0 \quad (\text{parameter model tidak signifikan})$$

$$H_1 : \hat{\theta} \neq 0 \quad (\text{parameter model signifikan})$$

Statistik uji

(2.39)

$$t = \frac{\hat{\theta}}{SE(\hat{\theta})}$$

Daerah penolakan

Tolak H_0 jika $|t| > t_{\alpha/2}$; $df = n - n_p$, n_p = banyaknya parameter atau dengan menggunakan nilai-p (p - value), yakni tolak H_0 jika nilai-p $< \alpha$.²⁵

H. Uji Augmented Dickey-Fuller (ADF Test)

Untuk mengukur kestasioneran data yang sudah dijelaskan diatas dapat dilakukan dengan menggunakan suatu uji. Uji yang biasa digunakan adalah uji *augmented Dickey-Fuller* atau uji lain yang serupa yaitu Uji *Phillips-Perron*. Perlu diketahui bahwa data yang dikatakan stasioner adalah data yang bersifat flat, tidak mengandung komponen trend, dengan keragaman yang konstan, serta tidak terdapat fluktuasi periodik.²⁶ Untuk diketahui adanya akar unit, maka dilakukan pengujian *Dickey-Fuller* (DF-test) sebagai berikut:

Jika variabel Z_t sebagai variabel independen maka akan diubah menjadi

$$Z_t = \rho Z_{t-1} + \varepsilon_t \quad (2.40)$$

Jika koefisien $\rho = 1$ maka model menjadi *random walk* tanpa *trend* yang berarti hipotesis diterima, maka variabel Z_t mengandung *unit root* dan bersifat non-stasioner. Agar data bersifat stasioner maka dilakukan uji orde pertama (*first difference*).²⁷

²⁵ Aswi dan Sukarna, *Analisis Deret Waktu*, (Makassar: Andira Publisher, 2006), h.125

²⁶ Bunga Lety M, *Pemodelan Dan Peramalan Penutupan Harga Saham Pt. Telkom Dengan Metode Arch – Garch*. H.2

²⁷ Ade Irma, 2014, *Analisis Model Neuro-Garch Dan Model Backpropagation Untuk Peramalan Indeks Harga Saham Gabungan*. H. 17

Bila persamaan diatas dikurangi pada Z_{t-1} sisi kanan dan kiri maka persamaannya menjadi

$$\Delta Z_t = (\rho - 1)(Z_t - Z_{t-1}) \quad (2.41)$$

Koefisien ρ akan bernilai 0, dan hipotesis akan ditolak sehingga model menjadi stasioner. Hipotesis yang digunakan pada pengujian *augmented dickey fuller* adalah :

$H_0 : \rho = 0$ (Terdapat unit roots, variabel Y tidak stasioner)

$H_1 : \rho \neq 0$ (Tidak terdapat unit roots, variabel Y stasioner)

Kesimpulan hasil root test diperoleh dengan membandingkan nilai t-hitung dengan nilai α .²⁸

I. Proses White Noise

Suatu proses $\{\varepsilon_t\}$ disebut proses white noise jika seriesnya terdiri dari variabel random yang tidak berkorelasi dan berdistribusi normal dengan rata-rata konstan $E(\varepsilon_t) = 0$, variansi konstan $Var(\varepsilon_t) = \sigma_t^2$ dan $\gamma_k = Cov \varepsilon_t, \varepsilon_{t+k} = 0$ untuk $k \neq 0$. Dengan demikian proses white noise stasioner dengan fungsi autokovariansi

$$\gamma_k = \begin{cases} \sigma_t^2, & \text{jika } k = 0 \\ 0, & \text{jika } k \neq 0 \end{cases}$$

Fungsi autokorelasi

$$\rho_k = \begin{cases} 1, & \text{jika } k = 0 \\ 0, & \text{jika } k \neq 0 \end{cases}$$

Fungsi autokorelasi parsial

$$\phi_{kk} = \begin{cases} 1, & \text{jika } k = 0 \\ 0, & \text{jika } k \neq 0 \end{cases}$$

²⁸ Bunga Lety M, *Pemodelan Dan Peramalan Penutupan Harga Saham Pt. Telkom Dengan Metode Arch – Garch*. H.3

Proses white noise dapat dideteksi menggunakan uji autokorelasi residual pada analisis error-nya. Uji korelasi residual digunakan untuk mendeteksi ada tidaknya korelasi residual antar lag. Langkah-langkah pengujian korelasi residual, yaitu

H_0 : $\rho_1 = \rho_2 = \rho_3 = \dots = \rho_k = 0$ (residual memenuhi syarat white noise)

H_1 : minimal ada satu $\rho_i \neq 0$, untuk $i = 1, 2, \dots, k$ (residual tidak white noise)

Taraf signifikan atau $\alpha = 5\%$

Statistik uji yaitu uji Ljung Box-Pierce. Rumus uji Ljung Box-Pierce

$$Q_K = T(T + 2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{T-K} \quad (2.42)$$

Dengan

T : banyaknya data

K : banyaknya lag yang diuji

$\hat{\rho}_k$: dugaan autokorelasi residual periode k

Kriteria keputusan yaitu tolak H_0 jika Q-hitung $> \chi^2_{(\alpha, df)}$ tabel, dengan derajat kebebasan K dikurangi banyaknya parameter pada model atau p-value $< \alpha$, artinya ε_t adalah barisan yang tidak memiliki korelasi.²⁹

J. Model ARCH dan GARCH

Dalam model-model ekonometrik konvensional, varian dari residual diasumsikan konstan di sepanjang waktu. Akan tetapi pada banyak kasus terutama untuk data keuangan terdapat fluktuasi yang tidak wajar pada suatu periode yang diikuti oleh periode berikutnya yang mungkin lebih stabil. Dalam kondisi asumsi varian konstan (homoskedastisitas) tidak terpenuhi,

²⁹ Mutiah, dkk, *Buku Ajar Time Series Analysis*, (Surabaya: Institut Teknologi Sepuluh November, 2013), h.112

banyak pendekatan yang digunakan untuk mengatasinya misalnya dengan mentransformasi datanya supaya variansnya menjadi lebih stabil.³⁰

Engle memperkenalkan suatu model dalam analisis deret waktu yang memperlakukan variansi dari *error* sebagai proses *autoregressive* (AR), kemudian dikenal sebagai model *Autoregressive Conditional Heteroscedasticity* (ARCH) dengan mengenalkan konsep *conditional heteroscedasticity*.³¹ Model ini digunakan untuk mengatasi keheterogenan ragam dengan memodelkan fungsi rata-rata dan fungsi ragam secara simultan.³²

Selanjutnya Bollerslev mengembangkan model ARCH menjadi model *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH), yang memungkinkan variansi dari *error* sebagai proses *Autoregressive Moving Average* (ARMA).³³ Model GARCH memiliki karakteristik respon volatilitas yang simetris terhadap guncangan. Dengan kata lain, sepanjang intensitasnya sama maka respon volatilitas terhadap suatu guncangan adalah sama, baik guncangan positif (*good news*) maupun negatif (*bad news*).

Adapun bentuk umum model GARCH (p,q) adalah sebagai berikut

$$Y_t = c + \gamma_1 X_{t-1} + \dots + \gamma_p X_{t-p} + \varepsilon_t \quad (2.43)$$

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \dots + \alpha_p \varepsilon_{t-p}^2 + \beta_1 \sigma_{t-1}^2 + \dots + \beta_q \sigma_{t-q}^2 \quad (2.44)$$

Dimana :

Y_t = variabel dependent

³⁰ Bunga Letty Malvira, *Pemodelan Dan Peramalan Penutupan Harga Saham Pt. Telkom Dengan Metode Arch – Garch*

³¹ Bagus Dwiantoro, “Peramalan Beban Listrik Jangka Pendek Berdasarkan Data Historis Menggunakan Metode Generalized Autoregressive Conditional Hetetockedasticity (GARCH)”, *Skripsi* (Depok: Universitas Indonesia, 2012), h.13.

³² Susanti, “Analisis Model Threshold Garch Dan Model Exponential Garch Pada Peramalan Ihsg”, *Skripsi* (Semarang: Universitas Negeri Semarang, 2015), h. 13

³³ Bagus Dwiantoro, “Peramalan Beban Listrik Jangka Pendek Berdasarkan Data Historis Menggunakan Metode Generalized Autoregressive Conditional Hetetockedasticity (GARCH)”, h.14.

γ_p	= koefisien variabel independen
X_{t-p}	= variabel independen
ε_t	= residual (<i>error</i>)
σ_t^2	= variansi residual
α_0	= konstanta pada persamaan ragam
$\alpha_1 \varepsilon_{t-1}^2$	= komponen ARCH pada saat waktu t-1
β_1	= konstanta pada komponen GARCH
$\alpha_p \varepsilon_{t-p}^2$	= komponen ARCH
$\beta_q \sigma_{t-q}^2$	= komponen GARCH

K. Uji ARCH-LM

Uji *Lagrange Multiplier* sering disebut sebagai ARCH-LM test. Uji ini digunakan untuk mendeteksi adanya heteroskedastisitas pada data, uji ini juga menunjukkan adanya efek ARCH yang menjadi pembahasan pada penelitian ini. Oleh karena itu, uji *Lagrange Multiplier* (ARCH-LM test) akan digunakan pada penelitian ini untuk menguji heteroskedastisitas dan efek ARCH. Pengujian untuk mengetahui masalah heteroskedastisitas dalam time series yang dikembangkan oleh Engle dikenal dengan uji ARCH-LM. Ide pokok uji ini adalah bahwa variansi residual bukan hanya fungsi dari variabel independen tetapi tergantung pada residual kuadrat pada periode sebelumnya.

Berikut merupakan langkah pengujian efek ARCH :³⁴

Hipotesis :

$H_0 : \alpha_0 = \alpha_1 = \dots = \alpha_p = 0$ (tidak terdapat efek ARCH dalam residualnya)

$H_1 : \text{minimal ada satu } \alpha_i \neq 0, \text{ untuk } i = 1, 2, \dots, p$ (ada efek ARCH dalam residualnya)

³⁴ Ade Irma Aprilia, "Analisis Model Neuro-Garch Dan Model Backpropagation Untuk Peramalan Indeks Harga Saham Gabungan", *Skripsi* (Medan: Universitas Sumatera Utara, 2014), h. 30

Statistik Uji :

$$F = \frac{\frac{(SSR_0 - SSR_1)}{p}}{\frac{SSR_1}{(T-2p-1)}} \quad (2.45)$$

Di mana :

$$SSR_0 = \sum_{t=p+1}^T (\varepsilon_t^2 - \omega)^2 \quad (2.46)$$

$$\omega = \frac{\sum_{t=1}^T \varepsilon_t^2}{T} \quad (2.47)$$

$$SSR_1 = \sum_{t=p+1}^T W_t^2 \quad (2.48)$$

Dengan

α = taraf signifikansi (0,05)

p = jumlah variabel independen

W_t^2 = residual kuadrat terkecil

ω = rata-rata sampel dari T

Kriteria Keputusan H_0 ditolak jika $F_{hit} > \chi_p^2(\alpha)$ atau $p - value < \alpha$

L. Model GJR-GARCH

Model GARCH yang telah diuraikan di atas memiliki karakteristik respons volatilitas yang simetris terhadap guncangan. Dengan kata lain, sepanjang intensitasnya sama maka respon volatilitas terhadap suatu guncangan adalah sama, baik guncangan positif (*good news*) maupun negatif (*bad news*).³⁵

Pengembangan model GARCH yang selanjutnya mengakomodasi kemungkinan adanya respon volatilitas yang asimetris. Dari literatur teori keuangan diketahui bahwa respons (dalam antrian gejolak pasar) lebih besar ketika news yang datang adalah bersifat negatif dari pada positif. Sebagai contoh, suatu berita tidak terduga mengenai laporan keuntungan perusahaan dapat

³⁵ Bambang Juanda, *Ekonometrika Deret Dan Waktu*, (Bogor: IPB Press, 2012), h. 97

memberikan dampak gejolak terhadap harga saham yang lebih besar ketika berita itu negatif (laporan rugi) dari pada positif (laporan untung). Hal ini terjadi bahkan ketika intensitas *news/surprise* tersebut adalah sama (nominal keuntungan / kerugian adalah sama).³⁶

Untuk memeriksa keberadaan pengaruh *leverage effect* (efek asimetris) salah satunya dapat dengan cara data runtun waktu dimodelkan ke dalam model GARCH. Kemudian dari model tersebut diuji ada tidaknya efek asimetris pada data dengan melihat korelasi antara ε_t^2 (residual kuadrat) dengan ε_t (lag residual) dengan menggunakan korelasi silang. Adanya asimetris ditandai dengan korelasi yang tidak sama dengan nol.

Untuk mengatasi persoalan guncanagn asimetris, ini terdapat dua model yang biasa digunakan, yaitu model TARCH (*Treshold ARCH*) atau biasa juga disebut dengan GJR-GARCH (*Glosten Jaganathan, dan Runkle*) dan EGARCH (*Exponential GARCH*).

Model TGARCH atau yang biasa juga disebut dengan GJR-GARCH pertama kali diperkenalkan oleh Glosten, Jaganathan dan Runkle pada tahun 1993. Persamaan model GJR-GARCH yaitu sebagai berikut :

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \cdots + \alpha_p \varepsilon_{t-p}^2 + \gamma \varepsilon_{t-1} d_{t-1} + \beta_1 \sigma_{t-1}^2 + \cdots + \beta_p \sigma_{t-p}^2 \quad (2.49)$$

Dimana d adalah peubah boneka (*dummy variable*) $d_{t-1} = 1$ jika $\varepsilon_{t-1} < 0$ dan $d_{t-1} = 0$ jika $\varepsilon_{t-1} > 0$.

Dalam model GJR-GARCH berita baik (*good news*) pada periode $t - 1(\varepsilon_{t-1} < 0)$ dan berita buruk (*bad news*) pada periode $t - 1(\varepsilon_{t-1} > 0)$ mempunyai efek berbeda terhadap *conditional variance*. Pada

³⁶ Doddy Ariefianto, *Ekonometrika Esensi Dan Aplikasi Dengan Menggunakan Eviews*. (Jakarta: Erlangga, 2012), h.102

1, berita baik mempunyai dampak terhadap α dan berita buruk mempunyai dampak terhadap $+\gamma$. jika $\gamma \neq 0$ maka terjadi efek asimetris.³⁷

M. Uji Akaike Information Criterion (AIC)

AIC digunakan untuk memilih model terbaik. Jika dua model dibandingkan, maka model dengan nilai AIC terkecil merupakan model yang lebih baik. Rumusan AIC adalah sebagai berikut :

$$AIC = \left(e^{\frac{2k}{n}} \right) \left(\frac{\sum e_i^2}{n} \right) = \left(e^{\frac{2k}{n}} \right) \left(\frac{SSE}{n} \right) \quad (2.50)$$

Di mana :

$$SSE = \text{Sum Square Error} = \sum e_i^2 = \sum (\hat{Z}_i - Z_i)^2$$

K = jumlah parameter dalam model

n = jumlah observasi (sampel)

N. Beban listrik

1. Peramalan Beban Listrik dan Ekonometrika

Ekonometrika adalah hasil dari suatu tinjauan tertentu tentang peran ilmu ekonomi, mencakup aplikasi statistik matematik atas data ekonomi guna memberikan dukungan empiris terhadap model yang disusun berdasarkan matematika ekonomi serta memperoleh hasil berupa angka-angka. Metode ekonometrik menggunakan analisis regresi untuk mendapatkan model yang digunakan dalam peramalan beban listrik.

Peramalan pada dasarnya merupakan suatu dugaan atau prakiraan mengenai terjadinya suatu kejadian atau peristiwa dimasa yang akan datang. Dalam kegiatan perencanaan peramalan merupakan kegiatan mula dari proses tersebut. Ramalan di bidang tenaga elektrik pada dasarnya merupakan ramalan kebutuhan energi elektrik (watt) dan ramalan beban tenaga elektrik (watt). Keduanya sering disebut dengan istilah Demand and Load Forecasting. Hasil

³⁷ Bambang Juanda, *Ekonometrika Deret Dan Waktu*, (Bogor: IPB Press, 2012), h. 97-98

peramalan ini dipergunakan untuk membuat rencana pemenuhan kebutuhan maupun pengembangan penyediaan tenaga elektrik setiap saat secara cukup dan baik serta terus menerus. Secara garis besar pembuatan ramalan kebutuhan tenaga elektrik dapat dibagi dalam tiga tahap, yaitu :

- a. Pengumpulan dan penyiapan data.
- b. Pengolahan dan analisa data.
- c. Penentuan metoda dan pembuatan model.³⁸

Menurut Bobby Fadilah perencanaan untuk sistem daya optimum dapat dibagi menjadi tiga macam yaitu: ³⁹

1) Perkiraan jangka panjang

Pada perencanaan sistem distribusi jangka panjang biasanya termasuk (tahun horison) dua belas tahun atau lebih sebelum saat sekarang: jangka waktu ini lebih besar untuk mempelajari transmisi atau pembangkitan utama. Kecuali diperkirakan pertumbuhan sangat sedikit, instalasi yang ada sedikit pengaruhnya dalam pengambilan keputusan. Sering kali keputusan diambil dengan bantuan studi standarisasi jaringan, termasuk model biaya.

2) Perkiraan jangka menengah

Jangka waktu untuk perencanaan jangka menengah ini antara tiga tahun sampai dua belas tahun, kebanyakan metode ekonomi untuk mengembangkan jaringan telah termasuk dalam parameter-parameter pada jangka panjang yang membahas pengembangan sistem dengan cara-cara lebih umum.

3) Perkiraan jangka pendek

³⁸ Daman Suswanto, *Analisis Peramalan Beban Dan Kebutuhan Energi Listrik*, h.201

³⁹ Bobby Fadilah, dkk, *Analisis Prakiraan Kebutuhan Energi Listrik Tahun 2015-2024 Wilayah Pln Kota Pekanbaru Dengan Metode Gabungan*”, (Vol 2 No. 2; Riau: Universitas Riau, 2015), h.2

Perkiraan jangka pendek atau rencana taktis memerlukan periode satu sampai tiga tahun dimuka dan biasanya hanya merupakan pelaksanaan hasil studi jangka panjang.

Tenaga listrik memiliki peranan yang sangat penting dalam kehidupan sehari-hari bagi para pemakainya terutama bagi sektor industri. Namun pada kenyataannya seringkali terjadi gangguan, baik gangguan yang disebabkan oleh alam (sambaran petir terhadap kawat saluran transmisi atau distribusi) maupun gangguan kerusakan peralatan karena saluran distribusi di Indonesia pada umumnya adalah saluran kabel udara, sehingga sering terjadi pemutusan dari suplai tenaga listrik.⁴⁰

Peramalan seharusnya bukan merupakan angka atau bilangan yang bisa digunakan begitu saja, karena hasil peramalan tidak pernah tepat 100%. Penggunaannya masih membutuhkan pertimbangan dari para pemakainya. Pengaruh yang diakibatkan kesalahan dalam peramalan itu berbeda serta sangat tergantung dari metoda yang dipakai dan perioda waktu yang digunakan dalam peramalan. Dalam peramalan ditetapkan pengoperasian dengan biaya terendah, tetapi akibat adanya kesalahan pada peramalan menyebabkan penggunaan sumber daya yang diperlukan berkurang. Jika peramalan yang dihasilkan itu tinggi maka dapat mengakibatkan banyaknya unit pembangkit yang dioperasikan dan banyaknya persediaan tenaga listrik yang tidak diperlukan. Sebaliknya apabila peramalan yang dihasilkan itu rendah maka dapat menghasilkan ketidaksanggupan dan ketidakandalan sistem dalam memenuhi kebutuhan. Kesalahan dalam peramalan juga dapat mengakibatkan kenaikan biaya operasi dan tingginya biaya pelayanan listrik.⁴¹

⁴⁰ Daman Suswanto, *Analisis Peramalan Beban dan Kebutuhan Energi Listrik*, h.204

⁴¹ Joseph Martua Napitupulu, "Prakiraan Kebutuhan Energi Listrik Di Pulau Nias Dengan Metode Ekonometri", *Skripsi* (Medan: Universitas Sumatera Utara, 2016), h.20

2. Beban Listrik

Beban adalah suatu kebutuhan energi listrik yang besarnya berubah-ubah tergantung kepada kebutuhan dari konsumen yang harus disuplai oleh PLN melalui sumber-sumber energi listrik.

Beban-beban tersebut dapat dikelompokkan menjadi :

- a. Beban harian, yaitu beban yang disuplai oleh PLN selama kurun waktu 24 jam atau selama satu hari satu malam.
- b. Beban bulanan, yaitu beban yang disuplai oleh PLN selama satu bulan atau selama 720 jam.
- c. Beban tahunan, yaitu beban yang harus disuplai oleh PLN kepada para pelanggan listrik selama satu tahun atau selama 8640 jam.⁴²

3. Karakteristik Beban

Karakteristik perubahan besarnya daya yang diterima oleh sistem tenaga kelistrikan setiap saat dalam suatu interval tertentu dikenal sebagai kurva beban harian. Tenaga listrik yang didistribusikan ke pelanggan (konsumen) digunakan sebagai sumber daya untuk bermacam-macam peralatan yang membutuhkan tenaga listrik sebagai sumber energinya. Peralatan tersebut umumnya bisa berupa lampu (penerangan), beban daya (untuk motor listrik), pemanas, dan sumber daya peralatan elektronik. Berdasarkan jenis konsumen energi listrik, secara garis besar, ragam beban dapat diklasifikasikan ke dalam:

- a. Beban rumah tangga, pada umumnya beban rumah tangga berupa lampu untuk penerangan, alat rumah tangga, seperti kipas angin, pemanas air, lemari es, penyejuk udara, mixer, oven, motor pompa air

⁴² Bobby Fadilah, dkk, *Analisis Prakiraan Kebutuhan Energi Listrik Tahun 2015-2024 Wilayah Pln Kota Pekanbaru Dengan Metode Gabungan*, (Vol 2 No. 2; Riau: Universitas Riau, 2015), h.5

dan sebagainya. Beban rumah tangga biasanya memuncak pada malam hari.

- b. Beban komersial, pada umumnya terdiri atas penerangan untuk reklame, kipas angin, penyejuk udara dan alat – alat listrik lainnya yang diperlukan untuk restoran. Beban hotel juga diklasifikasikan sebagai beban komersial (bisnis) begitu juga perkantoran. Beban ini secara drastis naik di siang hari untuk beban perkantoran dan pertokoan dan menurun di waktu sore.
- c. Beban industri dibedakan dalam skala kecil dan skala besar. Untuk skala kecil banyak beroperasi di siang hari sedangkan industri besar sekarang ini banyak yang beroperasi sampai 24 jam.
- d. Beban Fasilitas Umum Pengklasifikasian ini sangat penting artinya bila kita melakukan analisa karakteristik beban untuk suatu sistem yang sangat besar. Perbedaan yang paling prinsip dari empat jenis beban diatas, selain dari daya yang digunakan dan juga waktu pembebanannya.⁴³

UNIVERSITAS ISLAM NEGERI
ALAUDDIN
M A K A S S A R

⁴³ Daman Suswanto, *Analisis Peramalan Beban dan Kebutuhan Energi Listrik*, h.210

BAB III

METODELOGI PENELITIAN

A. Jenis Penelitian

Jenis penelitian yang dilakukan adalah terapan

B. Waktu Penelitian

Waktu pelaksanaan dalam penelitian ini yaitu terhitung dari bulan Maret 2017 sampai bulan Maret tahun 2018

C. Jenis Dan Sumber Data

Jenis data yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh dari PLN (Persero) Wilayah SULSELBAR pada periode Januari sampai pada Desember 2016

D. Variabel Dan Definisi Operasional

Variabel yang digunakan pada penelitian ini adalah variabel tingkat beban puncak energi listrik (Z_t) sebagai nilai inputan. Beban puncak terjadi ketika kebutuhan listrik konsumen menanjak ke titik yang paling tinggi di satu waktu tertentu, baik dalam rentang waktu jam, hari, minggu, bulan, hingga tahun.


E. Prosedur Penelitian

Adapun prosedur pada penelitian ini adalah

1. Melakukan uji stasioner pada data beban puncak, jika data belum stasioner maka dilakukan proses differencing atau transformasi.
2. Melakukan identifikasi model dengan melihat dan memperhatikan plot ACF dan PACF.
3. Mengestimasi parameter-parameter yang digunakan dengan menggunakan *Maximum Likelihood*

4. Membuat model ARIMA *Box Jenkins* dan memilih model terbaik pada model ARIMA dengan melihat nilai SICnya, dimana semakin kecil nilai SICnya maka semakin baik model tersebut.
5. Setelah diperoleh model ARIMAny kemudian mengecek apakah ada efek ARCH atau efek heteroskedastisitas dengan menggunakan *Lagrange Multiplier*, dan jika terdapat heteroskedastisitas maka permodelan GARCH dapat dilakukan.
6. Melakukan uji efek asimetris dengan menggunakan model GARCH :
 - a. Jika runtun waktu bersifat simetris, maka tetap menggunakan model GARCH.
 - b. Jika runtun waktu bersifat asimetris, maka menggunakan model TGARCH atau GJR-GARCH
7. Pemebentukan model GJR-GARCH dan mengestimasi parameternya dengan melakukan verifikasi model GJR-GARCH dengan melihat nilai AIC dan SIC
8. Melakukan Peramalan beban puncak energi listrik untuk beberapa periode kedepan

F. Flowcart Peramalan Menggunakan GJR-GARCH




BAB IV

HASIL DAN PEMBAHASAN

4.1 Hasil Penelitian

4.1.1 Pengujian Stasioneritas


Data yang digunakan untuk penelitian ini adalah beban puncak energi listrik untuk wilayah makassar yang merupakan data sekunder dan dimulai dari tanggal 1 Januari 2016 sampai pada tanggal 31 Desember 2016 dengan jumlah observasi 365 hari. Berdasarkan data pada Lampiran 1 maka dilakukan plot time series dan diperoleh hasilnya pada Gambar 4.1



Gambar 4.1 Grafik data Beban Puncak

Berdasarkan grafik pada Gambar 4.1 di atas dapat dilihat bahwa pola tren data runtun waktu tersebut tidak stasioner pada rata-rata karena terjadi perubahan rata-rata dari waktu ke waktu. Stasioner merupakan kondisi dimana nilai rata-rata dan varians dari data *time series* tersebut tidak mengalami perubahan secara sepanjang waktu atau konstan. Pengujian stasioner data runtun waktu dengan melihat grafik di atas memiliki kelemahan dalam objektivitas peneliti, karena setiap peneliti memiliki pandangan yang berbeda-beda, sehingga dibutuhkan uji formal yang akan menguatkan keputusan secara ilmiah. Uji formal yang dapat dilakukan adalah korelogram. Korelogram merupakan teknik identifikasi stasioner

data *time series* melalui fungsi autokorelasi. Berikut adalah plot ACF dan nilai autokorelasi yang dapat dilihat pada Gambar 4.2 dan Tabel 4.1



Gambar 4.2. Grafik fungsi autokorelasi beban puncak


Tabel 4.1 Autokorelasi data beban puncak

Lag	ACF	Lag	ACF	Lag	ACF	Lag	ACF	Lag	ACF
1	0,770	21	0,577	41	0,413	61	0,235	81	0,134
2	0,642	22	0,553	42	0,435	62	0,278	82	0,131
3	0,592	23	0,498	43	0,405	63	0,332	83	0,156
4	0,583	24	0,473	44	0,353	64	0,304	84	0,181
5	0,583	25	0,452	45	0,332	65	0,248	85	0,141
6	0,622	26	0,478	46	0,318	66	0,213	86	0,12
7	0,640	27	0,501	47	0,311	67	0,202	87	0,098
8	0,606	28	0,528	48	0,361	68	0,203	88	0,094
9	0,597	29	0,500	49	0,401	69	0,232	89	0,095
10	0,564	30	0,439	50	0,389	70	0,271	90	0,124
11	0,553	31	0,406	51	0,336	71	0,248	91	0,155
12	0,560	32	0,406	52	0,31	72	0,203	92	0,122
13	0,584	33	0,441	53	0,312	73	0,164	93	0,095
14	0,604	34	0,464	54	0,308	74	0,168	94	0,057
15	0,570	35	0,480	55	0,348	75	0,161	95	0,03
16	0,537	36	0,432	56	0,346	76	0,185	96	0,038
17	0,527	37	0,379	57	0,313	77	0,214	97	0,067
18	0,503	38	0,358	58	0,271	78	0,18	98	0,093
19	0,512	39	0,364	59	0,256	79	0,165	99	0,073
20	0,547	40	0,363	60	0,236	80	0,157	100	0,032

Dari grafik di atas dapat diidentifikasi bahwa nilai autokorelasinya turun lambat dengan kata lain nilai autokorelasinya tidak jauh berbeda dengan lag sebelumnya, Pada lag 1 nilai autokorelasinya yaitu 0,770, lag 2 yaitu 0,642 dan lag 3 yaitu 0,592, Nilai ini cenderung turun mengikuti setiap pertambahan lagnya, dan pada diagram terlihat bahwa banyak lagnya yang melewati garis batas atas signifikan (*upper confident limit*) yang merupakan garis selang kepercayaan batas kesignifikan autokorelasi. Berdasarkan diagram autokorelasi tersebut dapat disimpulkan bahwa bentuk diagram ACF turun lambat melewati garis batas signifikan yang menandakan bahwa data beban puncak tersebut belum stasioner dalam rata-rata. Karena hasil yang diperoleh bahwa data beban puncak belum stasioner dalam rata-rata maka langkah yang dilakukan adalah dengan melakukan *differencing*,

4.1.2 Differencing

Untuk menstasionerkan data maka dilakukan *differencing* orde pertama. Berdasarkan data pada Lampiran 1, maka dilakukan *differencing* dan dilakukan plot hasil dari *differencing* orde pertama pada Gambar 4.3



Gambar 4.3 Plot data beban puncak setelah *differencing* 1

Selanjutnya untuk menguji kestasioneran data secara statistic maka dapat dilakukan Uji ADF Test dengan menggunakan *differencing* orde pertama dan diperoleh hasil pada Tabel 4.2.


Tabel 4.2 Uji *Augmented Dickey –Fuller* Data Beban Puncak
Differencing Orde Pertama

	<i>T-Statistic</i>	<i>Probability</i>
<i>Augmented Dickey-Fuller</i>	-10,847	0,01

Dari Tabel 4.2 diperoleh nilai ADF probabilitas sebesar 0,01. Nilai ini lebih kecil dari taraf signifikan 5%, Karena nilainya lebih kecil maka H_0 ditolak yang berarti bahwa data hasil *differencing* orde pertama sudah stasioner, maka tidak perlu dilakukan *differencing* orde 2 karena data tersebut telah stasioner pada orde pertama. Karena data tersebut telah stasioner maka dilanjutkan dengan mengidentifikasi modelnya.

4.1.3 Identifikasi Model *Box-Jenkins*

Untuk melakukan tahap identifikasi model AR dan MA dari suatu data *time series* dapat dilakukan dengan melihat plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) pada berbagai lag. Berdasarkan data dari hasil *differencing* maka diperoleh nilai ACF beserta nilai autokorelasinya yang ditampilkan pada Tabel 4.3 dan Gambar 4.4




Gambar 4.4 Plot ACF Beban puncak setelah proses *differencing* 1

Tabel 4.3 Nilai autokorelasi setelah *differencing* 1

Lag	ACF	Lag	ACF	Lag	ACF	Lag	ACF	Lag	ACF
1	-0,218	21	0,116	41	0,053	61	-0,102	81	-0,043
2	-0,175	22	0,075	42	0,115	62	-0,026	82	-0,06
3	-0,079	23	-0,072	43	0,056	63	0,18	83	-0,014
4	-0,01	24	0,003	44	-0,077	64	0,058	84	0,138
5	-0,085	25	-0,101	45	0,005	65	-0,044	85	-0,043
6	0,039	26	0,023	46	-0,024	66	-0,039	86	-0,002
7	0,12	27	-0,009	47	-0,139	67	-0,022	87	-0,011
8	-0,07	28	0,119	48	0,024	68	-0,082	88	-0,029
9	0,047	29	0,062	49	0,117	69	-0,018	89	-0,061
10	-0,036	30	-0,07	50	0,092	70	0,148	90	-0,004
11	-0,046	31	-0,06	51	-0,062	71	0,044	91	0,142
12	-0,029	32	-0,089	52	-0,07	72	-0,027	92	-0,014
13	0,009	33	0,02	53	0,021	73	-0,093	93	0,011
14	0,113	34	0,016	54	-0,095	74	0,023	94	-0,024
15	0,001	35	0,125	55	0,093	75	-0,066	95	-0,066
16	-0,056	36	0,036	56	0,057	76	-0,012	96	-0,035
17	0,044	37	-0,067	57	0,019	77	0,144	97	0,007
18	-0,109	38	-0,055	58	-0,053	78	-0,041	98	0,098
19	-0,04	39	0,019	59	0,026	79	-0,018	99	0,026
20	0,005	40	-0,121	60	-0,043	80	0,04	100	-0,034

Dari diagram ACF dapat dilihat bahwa lagnya terpotong setelah lag 2 kemudian turun secara eksponensial dan membentuk gelombang sinus dengan nilai autokorelasi yang negatif dan positif, terlihat dari nilai autokorelasi pada lagi 1 yaitu -0,218, lag 2 yaitu -0,175, lag 3 yaitu -0,079 dan lag 4 yaitu -0,01 yang turun seiring dengan bertambah lagnya. Sehingga dugaan model yang dapat dibangkitkan adalah MA(2). Sedangkan untuk diagram PACF dan nilai autokorelasi parsialnya ditampilkan pada Gambar 4.5 dan Tabel 4.4 berikut



Gambar 4.5 Plot PACF Beban Puncak setelah proses *differencing* 1

Tabel 4.4 Nilai autokorelasi parsial setelah *differencing* 1

Lag	ACF	Lag	ACF	Lag	ACF	Lag	ACF	Lag	ACF
1	-0,218	21	-0,019	41	-0,025	61	-0,026	81	-0,016
2	-0,234	22	0,088	42	0,036	62	-0,132	82	0,046
3	-0,197	23	-0,033	43	0,041	63	0,033	83	-0,027
4	-0,148	24	0,026	44	0,005	64	0,043	84	0,054
5	-0,224	25	-0,059	45	0,027	65	0,014	85	-0,051
6	-0,137	26	-0,024	46	0,041	66	0,041	86	-0,036
7	-0,004	27	-0,036	47	-0,083	67	0,021	87	-0,009
8	-0,108	28	0,051	48	-0,1	68	-0,005	88	-0,017
9	0,012	29	0,119	49	-0,008	69	-0,059	89	-0,031
10	-0,045	30	0,043	50	0,02	70	0,019	90	-0,011

11	-0,071	31	-0,016	51	-0,007	71	0,072	91	0,039
12	-0,074	32	-0,064	52	-0,075	72	0,008	92	-0,053
13	-0,094	33	-0,04	53	0,032	73	-0,021	93	0,011
14	0,046	34	-0,044	54	-0,056	74	0,049	94	-0,027
15	0,025	35	0,055	55	0,034	75	0,004	95	0,008
16	-0,039	36	0,057	56	0,008	76	-0,039	96	-0,005
17	0,074	37	0,009	57	0,01	77	0,039	97	0,013
18	-0,091	38	-0,039	58	-0,01	78	-0,08	98	0,011
19	-0,084	39	0,037	59	0,044	79	-0,052	99	0,004
20	-0,103	40	-0,111	60	0,028	80	0,027	100	-0,029

Berdasarkan diagram PACF dapat dilihat bahwa ada beberapa lag yang tidak signifikan atau keluar dari batas signifikan yaitu sampai pada lag 6, yang kemudian mengalami *dies down* atau menurun seiring bertambah lagnya dengan membentuk gelombang sinus dengan tanda positif dan negatif, dilihat dari nilai autokorelasi pada lag 1 yaitu -0,218, lag 2 yaitu -0,234, lag 3 yaitu -0,197, lag 4 yaitu -0,148, lag 5 yaitu -0,224 dan lag 6 yaitu -0,137, sehingga dugaan model yang dapat dibangkitkan adalah model AR(6). Jadi berdasarkan diagram ACF dan PACF maka estimasi modelnya sementara adalah model ARIMA (1,1,1), ARIMA (2,1,1), ARIMA (3,1,1), ARIMA (4,1,1), ARIMA (5,1,1), ARIMA (6,1,1), ARIMA (1,1,2), ARIMA (2,1,2), ARIMA (3,1,2), ARIMA (4,1,2), ARIMA (5,1,2) dan ARIMA(6,1,2).

4.1.4 Estimasi Parameter Model ARIMA

Setelah mengidentifikasi model ARIMA, langkah selanjutnya adalah mengestimasi model, Pada tahap ini dilakukan pengujian kelayakan model dengan mencari model terbaik dengan melihat nilai *Akaike Information Criterion* (SIC) yang terkecil. Estimasi dari model-model ARIMA ditunjukkan pada Tabel 4.5 berikut;

Tabel 4.5 Estimasi Model ARIMA

MODEL	PARAMETER	ESTIMASI	S,E	T-STATISTIC	AIC
ARIMA (1,1,1)	AR 1	0,4228	0,0573	7,378708551	3619,92
	MA 1	-0,9126	0,0239	-38,18410042	
ARIMA (2,1,1)	AR 1	0,4404	0,0591	7,45177665	3618,3
	AR 2	-0,1082	0,0565	-1,915044248	
	MA 1	-0,8921	0,0302	-29,5397351	
ARIMA (3,1,1)	AR 1	0,4216	0,0636	6,628930818	3619,49
	AR 2	-0,0952	0,0583	-1,632933105	
	AR 3	-0,0528	0,0585	-0,902564103	
	MA 1	-0,8782	0,037	-23,73513514	
ARIMA (4,1,1)	AR 1	0,4022	0,0702	5,729344729	3620,86
	AR 2	-0,1064	0,0599	-1,776293823	
	AR 3	-0,0452	0,0597	-0,757118928	
	AR 4	-0,0479	0,0603	-0,794361526	
	MA 1	-0,8608	0,0477	-18,04612159	
ARIMA (5,1,1)	AR 1	0,3488	0,0999	3,491491491	3621,46
	AR 2	-0,1311	0,0663	-1,977375566	
	AR 3	-0,0744	0,0676	-1,100591716	
	AR 4	-0,048	0,0637	-0,753532182	
	AR 5	-0,0794	0,0688	-1,154069767	
	MA 1	-0,8092	0,0884	-9,153846154	
ARIMA (6,1,1)	AR 1	0,4226	0,082	5,153658537	3621,39
	AR 2	-0,099	0,0632	-1,566455696	
	AR 3	-0,0379	0,0646	-0,586687307	
	AR 4	-0,0106	0,0635	-0,166929134	
	AR 5	-0,0764	0,0613	-1,246329527	
	AR 6	0,0931	0,0632	1,473101266	
	MA 1	-0,8787	0,0608	-14,45230263	
ARIMA (1,1,2)	AR 1	0,2433	0,1271	1,914240755	3619,03
	MA 1	-0,7001	0,125	-5,6008	
	MA 2	-0,1808	0,1019	-1,774288518	
ARIMA (2,1,2)	AR 1	0,9038	0,2716	3,327687776	3619
	AR 2	-0,3134	0,1148	-2,729965157	
	MA 1	-1,3605	0,2771	-4,909779863	
	MA 2	0,4327	0,2516	1,719793323	
ARIMA (3,1,2)	AR 1	0,8533	0,4116	2,073129252	3620,95
	AR 2	-0,2867	0,1938	-1,479360165	
	AR 3	-0,016	0,0833	-0,192076831	
	MA 1	-1,3122	0,4084	-3,213026445	

	MA 2	0,3916	0,3611	1,084464137	
ARIMA (4,1,2)	AR 1	0,6342	0,4455	1,423569024	3622,62
	AR 2	-0,2086	0,1962	-1,063200815	
	AR 3	-0,0224	0,0752	-0,29787234	
	AR 4	-0,0434	0,0676	-0,642011834	
	MA 1	-1,0936	0,4434	-2,466396031	
	MA 2	0,2084	0,3876	0,537667699	
ARIMA (5,1,2)	AR 1	0,0987	0,3114	0,316955684	3622,94
	AR 2	-0,032	0,1497	-0,213760855	
	AR 3	-0,1022	0,0697	-1,466284075	
	AR 4	-0,0573	0,0649	-0,882896764	
	AR 5	-0,0985	0,0647	-1,522411128	
	MA 1	-0,558	0,3093	-1,804073715	
	MA 2	-0,2152	0,2716	-0,792341679	
ARIMA (6,1,2)	AR 1	0,7222	0,3706	1,948731786	3622,83
	AR 2	-0,2116	0,1593	-1,328311362	
	AR 3	-0,0022	0,0792	-0,027777778	
	AR 4	0,0084	0,0705	0,119148936	
	AR 5	-0,067	0,0673	-0,995542348	
	AR 6	0,1167	0,0615	1,897560976	
	MA 1	-1,1806	0,3706	-3,1856449	
	MA 2	0,2526	0,3154	0,800887762	

Sebagaimana merujuk pada lampiran 3 pada bagian output hasil estimasi parameter model ARIMA tersajikan pada masing-masing model pada Tabel 4.5 diperoleh nilai AIC yang terkecil yaitu model ARIMA (2,1,1). Untuk pengujian estimasi parameter dari model tersebut dapat dilihat dari nilai $|t|$ kemudian dibandingkan dengan nilai t tabel. Untuk parameter AR1 nilai $t = 7,451$, parameter AR2 nilai $t = -1,915$ dan untuk parameter MA1 nilai $t = -29,53$, sedangkan untuk mengetahui nilai t tabel dapat dilihat pada lampiran 4 dan diperoleh nilai $t_{\alpha/2;df} = 1,96$, maka disimpulkan hasil $|t| > t_{\alpha/2;df}$ untuk parameter AR1 dan MA2 yang berarti bahwa model AR1 dan MA2 berpengaruh secara signifikan terhadap data, sedangkan untuk parameter AR2 nilai $|t| < t_{\alpha/2;df}$, maka parameter AR2 berpengaruh terhadap model namun tidak secara signifikan atau tidak memberi pengaruh besar terhadap model. Dan berdasarkan uji kelayakan model diperoleh

nilai $p\text{-value} < \alpha$ maka dapat disimpulkan bahwa model telah memenuhi asumsi *white noise* dan berdistribusi normal.

4.1.6 Uji Pengaruh ARCH

Dalam melakukan uji pengaruh ARCH model yang akan diuji adalah model ARIMA (2,1,1) dengan menggunakan uji ARCH-LM, Hasil uji ARCH-LM dapat dilihat pada Tabel 4.6

Tabel 4.6 Uji ARCH-LM

Chi Square	25,153
P-Value	0,01411

Berdasarkan Tabel 4.6 diperoleh nilai *Chi Square* sebesar 25,153 dengan nilai *P-Value* 0,0141. Karena nilai $p\text{-value}$ yang diperoleh $< \alpha$ dimana nilai $\alpha = 0.05$ maka tolak H_0 yang berarti terdapat efek ARCH pada model ARIMA (2,1,1).

4.1.7 Pendugaan Parameter GARCH

Untuk mengatasi pengaruh ARCH, dilakukan dengan memodelkan data beban puncak dalam fungsi rata-rata dan fungsi ragam. Model ragam pertama yang akan digunakan adalah model GARCH. Pendugaan parameter dari GARCH dilakukan dengan metode *Maximum Log Likelihood*. Dalam penentuan model sementara untuk model GARCH dapat diambil dari nilai GARCH terkecil yaitu berkisar diantara nilai GARCH (1,1) sampai pada GARCH (2,2). Merujuk pada lampiran 3 untuk output pendugaan parameter GARCH maka dapat disajikan pada tabel 4.7

Tabel 4.7 Pendugaan Parameter GARCH

MODEL	PARAMETER	ESTIMASI	AIC
GARCH (1,1)	μ	0,1073	9,891432
	ϕ_1	0,4552	
	ϕ_2	-0,1006	
	θ_1	-0,8919	
	ω	985,48	
	α_1	0,1371	
	β_1	0,0000	
GARCH (1,2)	μ	0,1080	9,897312
	ϕ_1	0,4557	
	ϕ_2	-0,1009	
	θ_1	-0,8919	
	ω	988,06	
	α_1	0,1339	
	β_1	0,0000	
	β_2	0,0000	
GARCH (2,1)	μ	0,1080	9,897312
	ϕ_1	0,4557	
	ϕ_2	-0,1009	
	θ_1	-0,8919	
	ω	988,06	
	α_1	0,1339	
	α_2	0,0000	
	β_1	0,0000	
GARCH (2,2)	μ	0,1080	9,902791
	ϕ_1	0,4557	
	ϕ_2	-0,1009	
	θ_1	-0,8919	
	ω	988,06	
	α_1	0,1339	
	α_2	0,0000	
	β_1	0,0000	
	β_2	0,0000	

4.1.8 Pemilihan Model Terbaik GARCH

Berdasarkan Tabel 4.7 diperoleh model terbaik yaitu model ARIMA (2,1,1) GARCH (1,1) dengan melihat nilai AIC terkecil, maka model dari ARIMA (2,1,1) GARCH (1,1),

$$Z_t = 0,1073 + 0,4552Z_{t-1} - 0,1006Z_{t-2} - 0,8919\varepsilon_{t-1} + \varepsilon_t$$

Dan

$$\sigma_t^2 = 985,48 + 0,1371\varepsilon_{t-1}^2 + 0,000\sigma_{t-1}^2$$

4.1.9 Pendugaan Parameter GJR-GARCH atau TGARCH

Karena model ARIMA(2,1,1) GARCH(1,1) bersifat asimetris maka dilakukan pendugaan model TGARCH. Untuk menduga model TGARCH dilakukan dengan menggunakan metode *trial and error*. Untuk itu indentifikasi model GJR-GARCH sederhana menggunakan model GJR-GARCH (1,1), GJR-GARCH(1,2), GJR-GARCH(2,1) dan GJR-GARCH(2,2). Hasil dari pendugaan parameter GJR-GARCH disajikan dalam Tabel 4.8 yang diperoleh pada lampiran 3 output pendugaan parameter model GJR-GARCH.

Tabel 4.8 Hasil pendugaan Parameter GJR-GARCH

MODEL	PAREMATER	ESTIMASI	AIC
GJR GARCH (1,1)	μ	0,1050	9,896821
	ϕ_1	0,4584	
	ϕ_2	-0,1031	
	θ_1	-0,8912	
	ω	992,09	
	α_1	0,1292	
	γ_1	0,0524	
	β_1	0,0000	
GJR GARCH (1,2)	μ	0,1100	9,904899
	ϕ_1	0,4802	
	ϕ_2	-0,1166	
	θ_1	-0,8870	
	ω	1056	
	α_1	0,0321	
	γ_1	1,0000	

	β_1	0,0000	
	β_2	0,0000	
GJR GARCH(2,1)	μ	0,1055	9,908155
	ϕ_1	0,4594	
	ϕ_2	-0,1037	
	θ_1	-0,8911	
	ω	995,62	
	α_1	0,1249	
	α_2	0,0000	
	γ_1	0,0610	
	γ_2	-0,3355	
	β_1	0,0000	
	μ	0,1100	
	ϕ_1	0,4802	
GJR GARCH(2,2)	ϕ_2	-0,1166	9,915858
	θ_1	-0,8870	
	ω	1056	
	α_1	0,0321	
	α_2	0,0000	
	γ_1	1,0000	
	γ_2	0,8658	
	β_1	0,0000	
	β_2	0,0000	

4.1.10 Pemilihan Model GJR-GARCH

Berdasarkan Tabel 4.8 diperoleh model GJR-GARCH terbaik adalah model GJR-GARCH (1,1) dengan melihat nilai AIC terkecilnya, maka dapat dibuatkan persamaannya yaitu

$$Z_t = 0,1050 + 0,4584 Z_{t-1} - 0,1031 Z_{t-2} - 0,8912 \varepsilon_{t-1} + \varepsilon_t$$

Dan

$$\sigma_t^2 = 992,09 + 0,1292 \varepsilon_{t-1}^2 - 0,0524 d_{t-1} - 0,0000 \sigma_{t-1}^2$$

4.1.11 Peramalan Data Beban Puncak

Dalam penelitian ini, berdasarkan data pada Lampiran 1 dilakukan peralaman data beban puncak energi listrik untuk daerah Makassar dengan menggunakan model terbaik yang telah ditentukan sebelumnya yaitu model GJR-

GARCH (1,1). Merujuk pada lampiran 4 hasil peramalan beban puncak untuk 10 hari kedepan dapat dilihat pada Tabel 4.9 berikut

Tabel 4.9 Peramalan Data Beban Puncak

Hari Ke-	Tanggal	Peramalan	Lower	High
367	1/1/2017	974,5213	969,8403	979,2023
368	2/1/2017	974,5213	969,6727	979,3698
369	3/1/2017	974,5213	969,5108	979,5318
370	4/1/2017	974,5213	969,3539	979,6887
371	5/1/2017	974,5213	969,2016	979,8410
372	6/1/2017	974,5213	969,0535	979,9891
373	7/1/2017	974,5213	968,9093	980,1332
374	8/1/2017	974,5213	968,7688	980,2738
375	9/1/2017	974,5213	968,6315	980,4110
376	10/1/2017	974,5213	968,4974	980,5452

Dari model terbaik yang diperoleh dan dilakukan peramalan 10 periode kedepan diperoleh nilai peramalan yaitu 974,5213 cenderung konstan. Untuk periode 367 memiliki batas bawah nilai peramalan 969,8403 dan batas atas 979,2023, untuk periode 368 batas bawah nilai peramalan 969,6727 dan batas atas nilai peramalan 979,3698. Maksud dari batas-batas tersebut yaitu nilai peramalan berada pada batas tersebut.

4.2 Pembahasan

Penelitian ini menggunakan data beban puncak energi listrik untuk wilayah Makassar periode 1 januari 2016 sampai 31 Desember 2016, dimana jumlah observasinya adalah 266 observasi. Pada Gambar 4.1 terlihat pergerakan pola data beban puncak mengalami kenaikan mengikuti trend tertentu seiring berjalannya waktu, hal ini disebabkan karena semakin tinggi nilai beban puncak listrik untuk hari yang sama pada pekan atau periode berikutnya juga mengalami peningkatan. Terjadi peningkatan nilai beban puncak listrik pada periode 6 September 2016 kemudian diikuti dengan penurunan nilai beban puncak listrik pada periode berikutnya yaitu sampai pada periode 13 September 2016 dan

kemudian kembali mengalami kenaikan pada berikutnya. Nilai beban puncak tertinggi selama periode 1 Januari 2016 sampai 31 Desember 2016 terjadi pada periode 8 November 2016.

Berdasarkan data pada Lampiran 1 pada Gambar 4.1 terlihat bahwa pergerakan datanya tidak konstan terhadap rata-rata, kemudian dari hasil nilai autokorelasi diperoleh kesimpulan bahwa data tersebut tidak stasioner dalam rata-rata maka perlu dilakukan proses *differencing* orde pertama agar data beban puncak listrik stasioner. Setelah dilakukan proses *differencing* orde pertama maka dilakukan uji ADF untuk melihat kembali apakah data setelah *differencing* orde pertama sudah stasioner dan didapatkan nilai $p\text{-value} < \alpha$ yang berarti bahwa data hasil *differencing* sudah stasioner.

Hasil dari plot ACF setelah *differencing* orde pertama yaitu lagnya terpotong atau tidak signifikan setelah lag 2 dan plot PACF setelah *differencing* orde pertama lagnya terpotong setelah lag 6 maka estimasi model yang dapat dibuat adalah ARIMA (6,1,2). Dan untuk pemilihan model terbaik dapat dilihat dari nilai AIC terkecil maka diperoleh model terbaiknya adalah model ARIMA(2,1,1),

Uji efek ARCH menggunakan metode LM pada Tabel 4.6 menunjukkan bahwa terdapat pengaruh ARCH pada data beban puncak listrik yang berarti bahwa data beban puncak bersifat acak (*random*) dan memiliki volatilitas yang tinggi atau varian tidak konstan (heterokedastisitas). Oleh sebab itu, dibutuhkan model yang dapat digunakan untuk menguji efisiensi data beban puncak dengan kondisi heterokedastisitas yaitu model GARCH (*Generalized Autoregressive Conditional Heterokedasticity*).

Dari hasil pendugaan parameter model GARCH pada tabel 4.7 diperoleh model terbaik dengan memperhatikan nilai AIC terkecil yaitu model ARIMA(2,1,1) GARCH(1,1) maka dibuatkan persamaannya adalah

$$Z_t = 0,1073 + 0,4552Z_{t-1} - 0,1006Z_{t-2} - 0,8919\varepsilon_{t-1} + \varepsilon_t$$

Dan

$$\sigma_t^2 = 985,48 + 0,1371\varepsilon_{t-1}^2 + 0,000\sigma_{t-1}^2$$

Nilai beban puncak listrik pada waktu t dipengaruhi oleh nilai beban puncak listrik pada waktu $t - 1$ dan $t - 2$. Selain itu, nilai beban puncak listrik dipengaruhi nilai residual pada waktu $t - 1$. Nilai varian residual pada waktu t dipengaruhi oleh nilai residual kuadrat pada waktu $t - 1$ dan varian residual kuadrat pada waktu $t - 1$.

Setelah diperoleh model GARCH maka dilanjutkan dengan mencari model TGARCH atau GJR-GARCH dan diperoleh model terbaik yaitu model TGARCH (1,1) dengan memperhatikan nilai asimetris yang signifikan dan nilai AIC minimum,

Dari model terbaik yang diperoleh maka yaitu model GJR-GARCH (1,1) maka dapat dibuatkan persamaannya yaitu

$$Z_t = 0,1050 + 0,4584Z_{t-1} - 0,1031Z_{t-2} - 0,8912\varepsilon_{t-1} + \varepsilon_t$$

Dan

$$\sigma_t^2 = 992,09 + 0,1292\varepsilon_{t-1}^2 - 0,0524d_{t-1} - 0,0000\sigma_{t-1}^2$$

Nilai beban puncak listrik pada waktu t dipengaruhi oleh nilai beban puncak pada waktu $t - 1$ dan $t - 2$. Selain itu, nilai beban puncak listrik dipengaruhi nilai residual pada waktu $t - 1$, nilai varian residual pada waktu t dipengaruhi oleh nilai residual kuadrat pada waktu $t - 1$ dan varian residual kuadrat pada waktu $t - 1$.

Hasil peramalan ditunjukkan oleh Tabel 4.9, dengan menggunakan model GJR GARCH (1,1) selama 10 hari berikutnya yang ditandai dengan nilai peramalan yang konstan untuk periode hari ke-1 sampai pada hari ke-10 dengan nilai peramalannya yaitu berada pada nilai 974,5213 MW. Nilai ini cenderung turun dari nilai beban puncak pada periode sebelumnya, hal ini dikarenakan pada periode bulan September sering terjadi pemadaman arus listrik dikarenakan oleh banyak hal, seperti faktor alam dan kerusakan pada sistem PLN.



BAB V

PENTUPUP

5.1 Kesimpulan

Kesimpulan dalam penelitian ini adalah

1. Berdasarkan data beban puncak energi listrik untuk wilayah makassar diperoleh model terbaik yaitu model GJR-GARCH (1,1) atau TGARCH (1,1) yang dituliskan dalam persamaan berikut

$$Z_t = 0,1050 + 0,4584z_{t-1} - 0,1031z_{t-2} - 0,8912\varepsilon_{t-1} + \varepsilon_t$$

Dan

$$\sigma_t^2 = 992,09 + 0,1292\varepsilon_{t-1}^2 - 0,0524 d_{t-1} - 0,0000\sigma_{t-1}^2$$

2. Hasil peramalan nilai beban puncak energi listrik dengan menggunakan model TGARCH (1,1) untuk 10 hari berikutnya diperoleh hasil ramalan yang cenderung konstan dari periode 1 sampai pada periode 10 dengan nilai hasil ramalan 974,5213 MW,

5.2 Saran

Adapun saran untuk penelitian selanjutnya dapat menggunakan model Asimetris lainnya seperti model APARCH dan model EGARCH

UNIVERSITAS ISLAM NEGERI
ALAUDDIN
M A K A S S A R

DAFTAR PUSTAKA

- Ariefianto Doddy, 2012, *Ekonometrika Esensi Dan Aplikasi Dengan Menggunakan Eviews*. Jakarta: Erlangga.
- Aswi & Sukarna, 2006, *Analisis Deret Waktu*, Makassar: Andira Publisher.
- Departemen Agama RI, *Al-Qur'an dan Terjemahnya*
- Dwiantoro Bagus, 2012, *Peramalan Beban Listrik Jangka Pendek Berdasarkan Data Historis Menggunakan Metode Generalized Autoregressive Conditional Heteroskedasticity (GARCH)*. Depok : Universitas Indonesia
- Fadilah Bobby, dkk, 2015, “*Analisis Prakiraan Kebutuhan Energi Listrik Tahun 2015-2024 Wilayah Pln Kota Pekanbaru Dengan Metode Gabungan*”, Universitas Riau: Riau, Jom FTEKNIK Volume 2 No. 2 Oktober 2015
- Irma Aprilia Ade, 2014, “*Analisis Model Neuro-Garch Dan Model Backpropagation Untuk Peramalan Indeks Harga Saham Gabungan*“, Medan: Universitas Sumatera Utara
- Juanda Bambang & Junaidi, 2012, “*Ekonometrika Deret Waktu Teori dan Aplikasinya*”, IPB Press :Bogor
- Lumbantobing, Magdalena, 2008, *Peramalan Nilai Penjualan Energi Listrik di PT. PLN (PERSERO) Cabang Binjai*, Medan: Universitas Sumatera Utara.
- Letty Malvira Bunga, *Pemodelan Dan Peramalan Penutupan Harga Saham Pt. Telkom Dengan Metode Arch – Garch*
- Martua Napitupulu Joseph, 2016, “*Prakiraan Kebutuhan Energi Listrik Di Pulau Nias Dengan Metode Ekonometri*”, Medan: Universitas Sumatera Utara:
- Murray & Larry, 2004, “*Statistik Edisi Ketiga*”, Jakarta: Erlangga.
- Muthia, dkk. 2013. *Penerapan Metode Trend Moment Dalam Forecast Penjualan Motor Yamaha Di PT. Hasjrat Abadi*.
- Nurhayati Astin, 2010 (*Peramalan Jumlah Penumpang Pada Pt. Angkasa Pura I (Persero) Kantor Cabang Bandar Udara Internasional Adisutjipto Yogyakarta Dengan Metode Winter's Exponential Smoothing Dan Seasonal Arima*).
- Nur Samsiah Dewi. 2008. *Analisis Data Runtun Waktu Menggunakan Model Arima (P,D,Q)*. Yogyakarta: UIN Sunan Kalijaga
- Salamah Mutiah, dkk, 2003, *Buku Ajar Time Series Analysis*, Surabaya: Institut Teknologi Sepuluh November

Shihab Quraish, 2004, *Tafsir Al-Mishbah*, Jakarta: Lentera Hati.

Soejoeti, Zanzawi 1987, *Materi Pokok Analisis Runtun Waktu*, Jakarta: Univeristas Terbuka, Karunika

Sukma Ardita. 2010. *Perbandingan Metode Time Series Regression Dan Arimax Pada Pemodelan Data Penjualan Pakaian Di Boyolali*. Surabaya

Susansti, 2015, *Analisis Model Threshold Garch Dan Model Exponential Garch Pada Peramalan Ihsg*, Semarang: Universitas Negeri Semarang

Suswanto Daman, *Analisis Peramalan Beban Dan Kebutuhan Energi Listrik*.

Syukron Amin. 2014. “ *Pengantar Teknik Industri* “.Yogyakarta: Graha Ilmu

Tohir Akhmat. 2011. *Analisis Peramlan Penjualan Minyak Sawit Kasar Atau Crude Oil (CPO) Pada PT. Kharisma Pemasaran Bersama (KPB)*. UIN Syarif Hidayatullah



**L
A
M
P
I
R
A
N**

UNIVERSITAS ISLAM NEGERI
ALAUDDIN
M A K A S S A R

LAMPIRAN 1

Data beban Puncak Energi Listrik Wilayah Makassar Periode 01 Januari 2016 sampai 31 Desember 2017

Hari	JAN	FEB	MAR	APR	MAY	JUN
1	808,74	952,06	951,57	921,65	919,6	753,14
2	854,86	925,59	934,13	904,4	962,23	935,41
3	863,09	880,39	935,1	859,98	983,98	935,28
4	911,12	882,64	900,46	886,1	930,88	897,27
5	946,02	809,25	897,12	919,49	940,47	895,64
6	949,29	920,07	898,31	947,01	896,22	925,88
7	929,87	923,97	964,61	934,75	929,63	944,8
8	948,2	929,43	972,85	923,25	919,25	967,67
9	888,71	959,58	898,09	855,91	931,95	965,05
10	867,63	948,42	916,93	862,19	942,28	944,89
11	908,14	901,86	958,37	921,25	962,9	928,18
12	912,53	888,61	943,39	907,91	996,03	895,08
13	929,5	917,13	890,78	946,63	985,23	928,49
14	935,25	901,47	924,98	924,83	971,86	890,19
15	905,54	958,32	902,63	916,16	924,43	922,96
16	893,77	934,54	912,61	868,93	962,32	905,03
17	895,69	894,61	908,93	871,96	964,35	914,36
18	934,84	921,82	934,54	929,04	961,01	891,62
19	802,42	914,65	927,41	926,12	908,5	875,58
20	857,31	902,2	920,64	916,6	933,94	879,77
21	855,49	890,94	932,7	907,77	924,56	900,01
22	848,88	894,08	954,2	900,59	934,44	933,97
23	883,56	904,94	954,2	917,85	820,91	907,22
24	861,57	909,78	895,26	897,9	962,4	908,44
25	907,37	916,49	875,34	920,9	969,61	868,29
26	913,79	866,97	886,27	939,17	944,25	880,54
27	971,97	870,88	861,53	879,79	918,45	931,37
28	964,6	901,5	976,89	897,71	903,67	933,76
29	959,44	949,06	920,74	911,87	889,17	941,69
30	913,11		915,18	932,82	934,73	915,97
31	902,8		899,78		963,96	893

Hari	JUL	AUG	SEP	OCT	NOV	DEC
1	936,34	936,34	1.074,71	956,31	1.028,41	1.023,20
2	965,49	965,49	1.045,77	993,4	1.052,30	998,45
3	938,89	938,89	1.006,49	1.050,12	1.065,73	971,41
4	946,15	946,15	1.006,49	1.029,40	1.060,94	980,43
5	931,72	931,72	1.037,80	1.002,53	1.046,59	988,82
6	920,95	920,95	1.049,35	1.037,14	996,46	1.035,33
7	907,61	907,61	1.047,53	1.018,33	1.021,54	1.053,12
8	961,87	961,87	1.044,38	964,39	1.094,61	1.069,65
9	964,18	964,18	1.046,57	959,9	1.015,22	1.005,22
10	832,82	979,9	1.029,34	1.030,55	1.047,13	963,42
11	898,76	974,51	973,73	988,67	1.064,51	867,74
12	935,41	940,72	913,14	1.031,99	1.060,93	912,29
13	930,96	926,39	947,43	1.029,91	1.006,21	965,6
14	913,86	913,14	1.002,43	1.070,27	1.011,88	947,67
15	903,6	971,58	1.018,74	1.027,04	1.006,95	936,82
16	881,25	974,54	1.021,48	1.011,33	1.054,35	991,48
17	864,76	943,55	1.002,23	1.057,82	1.047,19	982,89
18	901,44	990,88	976,7	1.080,42	1.026,70	980,82
19	921,3	940,22	996,32	1.037,83	1.006,25	1.015,74
20	906,75	924,17	1.033,10	1.048,87	1.061,12	972,31
21	900,73	961	1.032,67	994,54	988,32	978,61
22	933,37	1.009,52	1.002,61	958,88	964,16	981,69
23	909,73	1.054,84	960,75	954,69	1.003,24	1.010,24
24	882,84	1.065,29	889,85	972,54	1.064,50	978,78
25	917,26	1.050,29	954,71	1.010,28	1.004,90	923,85
26	919,28	1.006,89	1.044,85	1.007,34	1.009,89	936,22
27	931,37	995,07	1.088,89	1.022,78	1.018,07	1.007,40
28	933,76	984,68	1.024,39	986,43	1.067,80	978,72
29	941,69	1.038,49	995,63	1.015,38	1.054,35	988,96
30	915,97	1.033,20	1.034,00	1.014,51	1.048,16	988,44
31	893	1.069,61		1.045,47		956,7

Data setelah differencing

No	DF1	NO	DF1	NO	DF1	NO	DF1	NO	DF1	NO	DF1
1	46.12	32	-26.47	63	-34.64	94	26.12	125	9.59	156	-1.63
2	8.23	33	-45.2	64	-3.34	95	33.39	126	-44.25	157	30.24
3	48.03	34	2.25	65	1.19	96	27.52	127	33.41	158	18.92
4	34.9	35	-73.39	66	66.3	97	-12.26	128	-10.38	159	22.87
5	3.27	36	110.82	67	8.24	98	-11.5	129	12.7	160	-2.62
6	-19.42	37	3.9	68	-74.76	99	-67.34	130	10.33	161	-20.16
7	18.33	38	5.46	69	18.84	100	6.28	131	20.62	162	-16.71
8	-59.49	39	30.15	70	41.44	101	59.06	132	33.13	163	-33.1
9	-21.08	40	-11.16	71	-14.98	102	-13.34	133	-10.8	164	33.41
10	40.51	41	-46.56	72	-52.61	103	38.72	134	-13.37	165	-38.3
11	4.39	42	-13.25	73	34.2	104	-21.8	135	-47.43	166	32.77
12	16.97	43	28.52	74	-22.35	105	-8.67	136	37.89	167	-17.93
13	5.75	44	-15.66	75	9.98	106	-47.23	137	2.03	168	9.33
14	-29.71	45	56.85	76	-3.68	107	3.03	138	-3.34	169	-22.74
15	-11.77	46	-23.78	77	25.61	108	57.08	139	-52.51	170	-16.04
16	1.92	47	-39.93	78	-7.13	109	-2.92	140	25.44	171	4.19
17	39.15	48	27.21	79	-6.77	110	-9.52	141	-9.38	172	20.24
18	-132.42	49	-7.17	80	12.06	111	-8.83	142	9.88	173	33.96
19	54.89	50	-12.45	81	21.5	112	-7.18	143	-113.53	174	-26.75
20	-1.82	51	-11.26	82	0	113	17.26	144	141.49	175	1.22
21	-6.61	52	3.14	83	-58.94	114	-19.95	145	7.21	176	-40.15
22	34.68	53	10.86	84	-19.92	115	23	146	-25.36	177	12.25
23	-21.99	54	4.84	85	10.93	116	18.27	147	-25.8	178	50.83
24	45.8	55	6.71	86	-24.74	117	-59.38	148	-14.78	179	2.39
25	6.42	56	-49.52	87	115.36	118	17.92	149	-14.5	180	7.93
26	58.18	57	3.91	88	-56.15	119	14.16	150	45.56	181	-25.72
27	-7.37	58	30.62	89	-5.56	120	20.95	151	29.23	182	20.37
28	-5.16	59	47.56	90	-15.4	121	-13.22	152	-210.82	183	29.15
29	-46.33	60	2.51	91	21.87	122	42.63	153	182.27	184	-26.6
30	-10.31	61	-17.44	92	-17.25	123	21.75	154	-0.13	185	7.26
31	49.26	62	0.97	93	-44.42	124	-53.1	155	-38.01		

No	DF1	NO	DF1	NO	DF1	NO	DF1	NO	DF1	NO	DF1
186	-14.43	216	7.26	246	-39.28	276	56.72	306	23.89	336	-24.75
187	-10.77	217	-14.43	247	0.9	277	-20.72	307	13.43	337	-27.04
188	-13.34	218	-10.77	248	31.31	278	-26.87	308	-4.79	338	9.02
189	54.26	219	-13.34	249	11.55	279	34.61	309	-14.35	339	8.39
190	2.31	220	54.26	250	-1.82	280	-18.81	310	-50.13	340	46.51
191	-131.36	221	2.31	251	-3.15	281	-53.94	311	25.08	341	17.79
192	65.94	222	15.72	252	2.19	282	-4.49	312	73.07	342	16.53
193	36.65	223	-5.39	253	-17.23	283	70.65	313	-79.39	343	-64.43
194	-4.45	224	-33.79	254	-55.61	284	-41.88	314	31.91	344	-41.8
195	-17.1	225	-14.33	255	-60.59	285	43.32	315	17.38	345	-95.68
196	-10.26	226	-13.25	256	34.29	286	-2.08	316	-3.58	346	44.55
197	-22.35	227	58.44	257	55	287	40.36	317	-54.72	347	53.31
198	-16.49	228	2.96	258	16.31	288	-43.23	318	5.67	348	-17.93
199	36.68	229	-30.99	259	2.74	289	-15.71	319	-4.93	349	-10.85
200	19.86	230	47.33	260	-19.25	290	46.49	320	47.4	350	54.66
201	-14.55	231	-50.66	261	-25.53	291	22.6	321	-7.16	351	-8.59
202	-6.02	232	-16.05	262	19.62	292	-42.59	322	-20.49	352	-2.07
203	32.64	233	36.83	263	36.78	293	11.04	323	-20.45	353	34.92
204	-23.64	234	48.52	264	-0.43	294	-54.33	324	54.87	354	-43.43
205	-26.89	235	45.32	265	-30.06	295	-35.66	325	-72.8	355	6.3
206	34.42	236	10.45	266	-41.86	296	-4.19	326	-24.16	356	3.08
207	2.02	237	-15	267	-70.9	297	17.85	327	39.08	357	28.55
208	12.09	238	-43.4	268	64.86	298	37.74	328	61.26	358	-31.46
209	2.39	239	-11.82	269	90.14	299	-2.94	329	-59.6	359	-54.93
210	7.93	240	-10.39	270	44.04	300	15.44	330	4.99	360	12.37
211	-25.72	241	53.81	271	-64.5	301	-36.35	331	8.18	361	71.18
212	-22.97	242	-5.29	272	-28.76	302	28.95	332	49.73	362	-28.68
213	43.34	243	36.41	273	38.37	303	-0.87	333	-13.45	363	10.24
214	29.15	244	5.1	274	-77.69	304	30.96	334	-6.19	364	-0.52
215	-26.6	245	-28.94	275	37.09	305	-17.06	335	-24.96	365	-31.74

LAMPIRAN 2

Program R

```
Bp<-read.csv(file.choose())
```

```
View(Bp)
```

```
plot.ts(Bp$beban)
```

```
#differencing
```

```
library(tseries)
```

```
df1=diff(Bp$beban)
```

```
plot.ts(df1)
```

```
#uji ADF
```

```
adf.test(df1)
```

```
#plot ACF dan PACF data differencing 1
```

```
acf.df1=acf(df1, main="ACF Beban setelah Differencing 1",  
lag.max="100", ylim=c(-0.5,1))
```

```
acf.df1
```

```
pacf.df1=pacf(df1, main="PACF Beban setelah differencing 1",  
lag.max="100", ylim=c(-0.5,1))
```

```
pacf.df1
```

```
#Estimasi Parameter ARIMA dan uji White Noise
```

```
arima110=arima(x=Bp, order= c(1,1,0))
```

```
arima110
```

```
Box.test(resid(arima110),type= "Ljung",lag=20,fitdf=1)
```

```
resid110=resid((arima110),lag=30,fitdf=1)
```

```
resid110
```

```
arima111=arima(x=Bp, order= c(1,1,1))
```


arima111

Box.test(resid(arima111),type="Ljung",lag=20,fitdf=1)

resid111=resid((arima111),lag= 20,fitdf=1)

resid111

arima112=arima(x=Bp, order= c(1,1,2))

arima112

Box.test(resid(arima112),type= "Ljung",lag=20,fitdf=1)

resid112=resid((arima112),lag=20,fitdf=1)

resid112

arima011=arima(x=Bp, order= c(0,1,1))

arima011

Box.test(resid(arima011),type= "Ljung",lag=20,fitdf=1)

resid011=resid((arima011),lag=20,fitdf=1)

resid011

arima012=arima(x=Bp, order= c(0,1,2))

arima012

Box.test(resid(arima012),type= "Ljung",lag=20,fitdf=1)

resid012=resid((arima012),lag=20,fitdf=1)

resid012

arima210=arima(x=Bp, order= c(2,1,0))

arima210

```
Box.test(resid(arima210),type= "Ljung",lag=20,fitdf=1)
```

```
resid210=resid((arima210),lag=20,fitdf=1)
```

```
resid210
```

```
arima211=arima(x=Bp, order= c(2,1,1))
```

```
arima211
```

```
Box.test(resid(arima211),type= "Ljung",lag=20,fitdf=1)
```

```
resid211=resid((arima211),lag=20,fitdf=1)
```

```
resid211
```

```
arima212=arima(x=Bp, order= c(2,1,2))
```

```
arima212
```

```
Box.test(resid(arima212),type= "Ljung",lag=20,fitdf=1)
```

```
resid212=resid((arima212), lag=20,fitdf=1)
```

```
resid212
```

```
arima311=arima(x=Bp, order= c(3,1,1))
```

```
arima311
```

```
Box.test(resid(arima311),type= "Ljung",lag=20,fitdf=0)
```

```
resid311=resid((arima311))
```

```
resid311
```

```
arima411=arima(x=Bp, order= c(4,1,1))
```

```
arima411
```

```
Box.test(resid(arima411),type= "Ljung",lag=20,fitdf=0)
```

```
resid411=resid((arima411),type= "Ljung",lag=20,fitdf=0)
```

```
resid411
```

```
arima511=arima(x=Bp, order= c(5,1,1))
```

```
arima511
```

```
Box.test(resid(arima511),type= "Ljung",lag=20,fitdf=0)
```

```
resid511=resid((arima511),type= "Ljung",lag=20,fitdf=0)
```

```
resid511
```

```
arima611=arima(x=Bp, order= c(6,1,1))
```

```
arima611
```

```
Box.test(resid(arima611),type= "Ljung",lag=20,fitdf=0)
```

```
resid611=resid((arima611),type= "Ljung",lag=20,fitdf=0)
```

```
resid611
```

```
arima312=arima(x=Bp, order= c(3,1,2))
```

```
arima312
```

```
Box.test(resid(arima312),type= "Ljung",lag=50,fitdf=0)
```

```
resid312=resid((arima312),type= "Ljung",lag=20,fitdf=0)
```

```
resid312
```

```
arima412=arima(x=Bp, order= c(4,1,2))
```

```
arima412
```

```
Box.test(resid(arima412),type= "Ljung",lag=20,fitdf=0)
```

```
resid412=resid((arima412),type= "Ljung",lag=20,fitdf=0)
```

```
resid412
```

```
arima512=arima(x=Bp, order= c(5,1,2))
```

```
arima512
```

```
Box.test(resid(arima512),type= "Ljung",lag=20,fitdf=0)
```

```
resid512=resid((arima512),type= "Ljung",lag=20,fitdf=0)
```

```
resid512
```

```
arima612=arima(x=Bp, order= c(6,1,2))
```

```
arima612
```

```
Box.test(resid(arima612),type= "Ljung",lag=20,fitdf=0)
```

```
resid612=resid((arima612),type= "Ljung",lag=20,fitdf=0)
```

```
resid612
```

```
#uji efek ARCH
```

```
library(FinTS)
```

```
ArchTest <- ArchTest(resid211, demean=TRUE)
```

```
ArchTest
```

```
#estimasi GARCH
```

```
library(tseries)
```

```
library(rugarch)
```

```
library(fGarch)
```

```
#ESTIMASI MODEL ARIMA(2,1,2) DENGAN MODEL GARCH
```

```
GARCH11 <- garchFit(~ arma(2,1) + garch(1,1), data = df1, trace = FALSE)
```

```
summary(GARCH11)
```

```
GARCH12 <- garchFit(~ arma(2,1) + garch(1,2), data = df1, trace = FALSE)
```

```
summary(GARCH12)
```

```
GARCH21 <- garchFit(~ arma(2,1) + garch(2,1), data = df1, trace = FALSE)
```

```
summary(GARCH21)
```

```
GARCH22 <- garchFit(~ arma(2,1) + garch(2,2), data = df1, trace = FALSE)
```

```
summary(GARCH22)
```

```
#estimasi model GJR
```

```
sp_tarch11 <- garchFit(~ arma(2,1) + garch(1,1), delta = 2, leverage = TRUE , data = df1, trace = FALSE)
```

```
summary(sp_tarch11)
```

```
sp_tarch12 <- garchFit(~ arma(2,1) + garch(1,2), delta = 2, leverage = TRUE , data = df1, trace = FALSE)
```

```
summary(sp_tarch12)
```

```
sp_tarch21 <- garchFit(~ arma(2,1) + garch(2,1), delta = 2, leverage = TRUE , data = df1, trace = FALSE)
```

```
summary(sp_tarch21)
```

```
sp_tarch22 <- garchFit(~ arma(2,1) + garch(2,2), delta = 2, leverage = TRUE , data = df1, trace = FALSE)
```

```
summary(sp_tarch22)
```

```
#Peramalan beban puncak menggunakan model GJR-GARCH (1,1)
```

```
forecast.tarch11<-forecast(Bp$beban, level = 10)
```

LAMPIRAN 3

Output

Uji akar unit (*Unit Root Test*) data DF1

```
Augmented Dickey-Fuller Test

data: df1
Dickey-Fuller = -10.847, Lag order = 7, p-value = 0.01
alternative hypothesis: stationary
```

Estimasi Model ARIMA

1. ARIMA (1,1,0)

```
> arima10=arima(x=Bp, order= c(1,1,0))
> arima10

Call:
arima(x = Bp, order = c(1, 1, 0))

Coefficients:
      ar1
    -0.2185
s.e.    0.0512

sigma^2 estimated as 1428:  log likelihood = -1843.67,  aic = 3691.35
> Box.test(resid(arima10),type= "Ljung",lag=20,fitdf=1)

Box-Ljung test

data: resid(arima10)
X-squared = 62.28, df = 19, p-value = 1.678e-06
```

2. ARIMA (1,1,1)

```
> arima11=arima(x=Bp, order= c(1,1,1))
> arima11

Call:
arima(x = Bp, order = c(1, 1, 1))

Coefficients:
      ar1      ma1
    0.4228  -0.9126
s.e.  0.0573   0.0239

sigma^2 estimated as 1165:  log likelihood = -1806.96,  aic = 3619.92
> Box.test(resid(arima11),type= "Ljung",lag=20,fitdf=1)

Box-Ljung test

data: resid(arima11)
X-squared = 26.138, df = 19, p-value = 0.1264
```

3. ARIMA (1,1,2)

```
> arima112=arima(x=Bp, order= c(1,1,2))
> arima112

Call:
arima(x = Bp, order = c(1, 1, 2))

Coefficients:
      ar1      ma1      ma2
    0.2433 -0.7001 -0.1808
s.e.  0.1271  0.1250  0.1019

sigma^2 estimated as 1156: log likelihood = -1805.52, aic = 3619.03
> Box.test(resid(arima112),type= "Ljung",lag=20,fitdf=1)

Box-Ljung test

data:  resid(arima112)
X-squared = 22.335, df = 19, p-value = 0.2679
```

4. ARIMA (0,1,1)

```
> arima011=arima(x=Bp, order= c(0,1,1))
> arima011

Call:
arima(x = Bp, order = c(0, 1, 1))

Coefficients:
      ma1
    -0.6839
s.e.  0.0901

sigma^2 estimated as 1325: log likelihood = -1830.26, aic = 3664.51
> Box.test(resid(arima011),type= "Ljung",lag=20,fitdf=1)

Box-Ljung test

data:  resid(arima011)
X-squared = 84.796, df = 19, p-value = 2.734e-10
```

5. ARIMA (0,1,2)

```
> arima012=arima(x=Bp, order= c(0,1,2))
> arima012

Call:
arima(x = Bp, order = c(0, 1, 2))

Coefficients:
      ma1      ma2
    -0.4921 -0.3362
s.e.  0.0462  0.0451

sigma^2 estimated as 1166: log likelihood = -1807.16, aic = 3620.31
> Box.test(resid(arima012),type= "Ljung",lag=20,fitdf=1)

Box-Ljung test

data:  resid(arima012)
X-squared = 26.067, df = 19, p-value = 0.1283
```


6. ARIMA (2,1,0)

```
> arima210=arima(x=Bp, order= c(2,1,0))
> arima210

Call:
arima(x = Bp, order = c(2, 1, 0))

Coefficients:
      ar1      ar2
    -0.2702  -0.2342
s.e.    0.0510   0.0509

sigma^2 estimated as 1350: log likelihood = -1833.39, aic = 3672.77
> Box.test(resid(arima210),type= "Ljung",lag=20,fitdf=1)

Box-Ljung test

data:  resid(arima210)
X-squared = 62.234, df = 19, p-value = 1.706e-06
```

7. ARIMA (2,1,1)

```
> arima211=arima(x=Bp, order= c(2,1,1))
> arima211

Call:
arima(x = Bp, order = c(2, 1, 1))

Coefficients:
      ar1      ar2      ma1
    0.4404  -0.1082  -0.8921
s.e.    0.0591   0.0565   0.0302

sigma^2 estimated as 1153: log likelihood = -1805.15, aic = 3618.3
> Box.test(resid(arima211),type= "Ljung",lag=20,fitdf=1)

Box-Ljung test

data:  resid(arima211)
X-squared = 21.229, df = 19, p-value = 0.3243
```

8. ARIMA (2,1,2)

```
> arima212=arima(x=Bp, order= c(2,1,2))
> arima212

Call:
arima(x = Bp, order = c(2, 1, 2))

Coefficients:
      ar1      ar2      ma1      ma2
    0.9038  -0.3134  -1.3605   0.4327
s.e.    0.2716   0.1148   0.2771   0.2516

sigma^2 estimated as 1149: log likelihood = -1804.5, aic = 3619
> Box.test(resid(arima212),type= "Ljung",lag=20,fitdf=1)

Box-Ljung test

data:  resid(arima212)
X-squared = 19.515, df = 19, p-value = 0.4243
```

9. ARIMA (3,1,1)

```
> arima311=arima(x=Bp, order= c(3,1,1))
> arima311
```

Call:
arima(x = Bp, order = c(3, 1, 1))

Coefficients:

	ar1	ar2	ar3	ma1
	0.4216	-0.0952	-0.0528	-0.8782
s.e.	0.0636	0.0583	0.0585	0.0370

sigma^2 estimated as 1151: log likelihood = -1804.75, aic = 3619.49

```
> Box.test(resid(arima311),type= "Ljung",lag=20,fitdf=0)
```

Box-Ljung test

data: resid(arima311)
X-squared = 20.071, df = 20, p-value = 0.4535

10. ARIMA (4,1,1)

```
> arima411=arima(x=Bp, order= c(4,1,1))
> arima411
```

Call:
arima(x = Bp, order = c(4, 1, 1))

Coefficients:

	ar1	ar2	ar3	ar4	ma1
	0.4022	-0.1064	-0.0452	-0.0479	-0.8608
s.e.	0.0702	0.0599	0.0597	0.0603	0.0477

sigma^2 estimated as 1149: log likelihood = -1804.43, aic = 3620.86

```
> Box.test(resid(arima411),type= "Ljung",lag=20,fitdf=0)
```

Box-Ljung test

data: resid(arima411)
X-squared = 18.655, df = 20, p-value = 0.5443

11. ARIMA (5,1,1)

```
> arima511=arima(x=Bp, order= c(5,1,1))
> arima511
```

Call:
arima(x = Bp, order = c(5, 1, 1))

Coefficients:

	ar1	ar2	ar3	ar4	ar5	ma1
	0.3488	-0.1311	-0.0744	-0.0480	-0.0794	-0.8092
s.e.	0.0999	0.0663	0.0676	0.0637	0.0688	0.0884

sigma^2 estimated as 1144: log likelihood = -1803.73, aic = 3621.46

```
> Box.test(resid(arima511),type= "Ljung",lag=20,fitdf=0)
```

Box-Ljung test

data: resid(arima511)
X-squared = 18, df = 20, p-value = 0.5874

12. ARIMA (6,1,1)

```
> arima611=arima(x=Bp, order= c(6,1,1))
> arima611
```

Call:
arima(x = Bp, order = c(6, 1, 1))

Coefficients:

	ar1	ar2	ar3	ar4	ar5	ar6	ma1
	0.4226	-0.0990	-0.0379	-0.0106	-0.0764	0.0931	-0.8787
s.e.	0.0820	0.0632	0.0646	0.0635	0.0613	0.0632	0.0608

sigma^2 estimated as 1138: log likelihood = -1802.69, aic = 3621.39
 > Box.test(resid(arima611),type= "Ljung",lag=20,fitdf=0)

Box-Ljung test

data: resid(arima611)
 X-squared = 15.96, df = 20, p-value = 0.7191

13. ARIMA (3,1,2)

```
> arima312=arima(x=Bp, order= c(3,1,2))
> arima312
```

Call:
arima(x = Bp, order = c(3, 1, 2))

Coefficients:

	ar1	ar2	ar3	ma1	ma2
	0.8533	-0.2867	-0.0160	-1.3122	0.3916
s.e.	0.4116	0.1938	0.0833	0.4084	0.3611

sigma^2 estimated as 1149: log likelihood = -1804.48, aic = 3620.95
 > Box.test(resid(arima312),type= "Ljung",lag=20,fitdf=0)

Box-Ljung test

data: resid(arima312)
 X-squared = 19.41, df = 20, p-value = 0.4953

14. ARIMA (4,1,2)

```
> arima412=arima(x=Bp, order= c(4,1,2))
> arima412
```

Call:
arima(x = Bp, order = c(4, 1, 2))

Coefficients:

	ar1	ar2	ar3	ar4	ma1	ma2
	0.6342	-0.2086	-0.0224	-0.0434	-1.0936	0.2084
s.e.	0.4455	0.1962	0.0752	0.0676	0.4434	0.3876

sigma^2 estimated as 1148: log likelihood = -1804.31, aic = 3622.62
 > Box.test(resid(arima412),type= "Ljung",lag=20,fitdf=0)

Box-Ljung test

data: resid(arima412)
 X-squared = 18.519, df = 20, p-value = 0.5532

15. ARIMA (5,1,2)

```
> arima512=arima(x=Bp, order= c(5,1,2))
> arima512

Call:
arima(x = Bp, order = c(5, 1, 2))

Coefficients:
      ar1      ar2      ar3      ar4      ar5      ma1      ma2
    0.0987 -0.0320 -0.1022 -0.0573 -0.0985 -0.5580 -0.2152
s.e.  0.3114  0.1497  0.0697  0.0649  0.0647  0.3093  0.2716

sigma^2 estimated as 1143: log likelihood = -1803.47, aic = 3622.94
> Box.test(resid(arima512),type= "Ljung",lag=20,fitdf=0)

Box-Ljung test

data: resid(arima512)
X-squared = 17.79, df = 20, p-value = 0.6012
```

16. ARIMA (6,1,2)

```
> arima612=arima(x=Bp, order= c(6,1,2))
> arima612

Call:
arima(x = Bp, order = c(6, 1, 2))

Coefficients:
      ar1      ar2      ar3      ar4      ar5      ar6      ma1      ma2
    0.7222 -0.2116 -0.0022  0.0084 -0.0670  0.1167 -1.1806  0.2526
s.e.  0.3706  0.1593  0.0792  0.0705  0.0673  0.0615  0.3706  0.3154

sigma^2 estimated as 1136: log likelihood = -1802.41, aic = 3622.83
> Box.test(resid(arima612),type= "Ljung",lag=20,fitdf=0)

Box-Ljung test

data: resid(arima612)
X-squared = 14.511, df = 20, p-value = 0.8037
```

UJI Efek ARCH Menggunakan ArchTest dengan Package “FinTs”

```
> ArchTest211<- ArchTest(resid211, demean=TRUE)
> ArchTest211

ARCH LM-test; Null hypothesis: no ARCH effects

data: resid211
Chi-squared = 25.153, df = 12, p-value = 0.01411
```

ESTIMASI MODEL GARCH

1. ARIMA (2,1,1) GARCH(1,1)

```
> GARCH11 <- garchFit(~ arma(2,1) + garch(1,1), data = df1, trace = FALSE)
> summary(GARCH11)
```

Title:

GARCH Modelling

Call:

garchFit(formula = ~arma(2, 1) + garch(1, 1), data = df1, trace = FALSE)

Mean and Variance Equation:

data ~ arma(2, 1) + garch(1, 1)

<environment: 0x1b98162c>

[data = df1]

Conditional Distribution:

norm

Coefficient(s):

	mu	ar1	ar2	ma1	omega	alpha1	beta1
	1.0734e-01	4.5517e-01	-1.0063e-01	-8.9192e-01	9.8548e+02	1.3706e-01	1.0000e-08

Std. Errors:

based on Hessian

Error Analysis:

	Estimate	Std. Error	t value	Pr(> t)
mu	1.073e-01	1.923e-01	0.558	0.57678
ar1	4.552e-01	7.028e-02	6.477	9.37e-11 ***
ar2	-1.006e-01	6.041e-02	-1.666	0.09576 .
ma1	-8.919e-01	3.414e-02	-26.124	< 2e-16 ***
omega	9.855e+02	3.296e+02	2.990	0.00279 **
alpha1	1.371e-01	8.067e-02	1.699	0.08932 .
beta1	1.000e-08	3.024e-01	0.000	1.00000

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Log Likelihood:

-1798.186 normalized: -4.926538

Description:

wed Mar 07 11:45:58 2018 by user: Rina

Standardised Residuals Tests:

			Statistic	p-value
Jarque-Bera Test	R	Chi^2	308.2146	0
Shapiro-wilk Test	R	W	0.9485304	5.741304e-10
Ljung-Box Test	R	Q(10)	9.098288	0.5228018
Ljung-Box Test	R	Q(15)	15.75328	0.3986359
Ljung-Box Test	R	Q(20)	22.01797	0.3395362
Ljung-Box Test	R^2	Q(10)	18.75996	0.0434197
Ljung-Box Test	R^2	Q(15)	20.15126	0.1662068
Ljung-Box Test	R^2	Q(20)	21.66121	0.3591735
LM Arch Test	R	TR^2	17.29998	0.1386572

Information Criterion Statistics:

AIC	BIC	SIC	HQIC
9.891432	9.966224	9.890715	9.921155

2. ARIMA (2,1,1) GARCH(1,2)

```
> GARCH12 <- garchFit(~ arma(2,1) + garch(1,2), data = df1, trace = FALSE)
> summary(GARCH12)
```

Title:

GARCH Modelling

Call:

garchFit(formula = ~arma(2, 1) + garch(1, 2), data = df1, trace = FALSE)

Mean and Variance Equation:

data ~ arma(2, 1) + garch(1, 2)

<environment: 0x13830914>

[data = df1]

Conditional Distribution:

norm

Coefficient(s):

	mu	ar1	ar2	ma1	omega	alpha1	beta1	beta2
	1.0800e-01	4.5569e-01	-1.0093e-01	-8.9191e-01	9.8806e+02	1.3389e-01	1.0000e-08	1.0000e-08

Std. Errors:

based on Hessian

Error Analysis:

	Estimate	Std. Error	t value	Pr(> t)
mu	1.080e-01	2.057e-01	0.525	0.59956
ar1	4.557e-01	7.001e-02	6.509	7.56e-11 ***
ar2	-1.009e-01	6.075e-02	-1.661	0.09664 .
ma1	-8.919e-01	3.515e-02	-25.376	< 2e-16 ***
omega	9.881e+02	3.379e+02	2.924	0.00346 **
alpha1	1.339e-01	9.903e-02	1.352	0.17636
beta1	1.000e-08	4.355e-01	0.000	1.00000
beta2	1.000e-08	3.676e-01	0.000	1.00000

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Log Likelihood:

-1798.259 normalized: -4.926738

Description:

wed Mar 07 11:47:46 2018 by user: Rina

Standardised Residuals Tests:

	Statistic	p-value
Jarque-Bera Test	R Chi^2 308.3256	0
Shapiro-wilk Test	R W 0.9485101	5.707864e-10
Ljung-Box Test	R Q(10) 9.093547	0.5232492
Ljung-Box Test	R Q(15) 15.72457	0.4005896
Ljung-Box Test	R Q(20) 21.99691	0.3406783
Ljung-Box Test	R^2 Q(10) 18.69884	0.04425887
Ljung-Box Test	R^2 Q(15) 20.08432	0.1687218
Ljung-Box Test	R^2 Q(20) 21.58486	0.3634553
LM Arch Test	R TR^2 17.23771	0.1408721

Information Criterion Statistics:

AIC	BIC	SIC	HQIC
9.897312	9.982789	9.896378	9.931281

3. ARIMA (2,1,1) GARCH (2,1)

```
> GARCH21 <- garchFit(~ arma(2,1) + garch(2,1), data = df1, trace = FALSE)
> summary(GARCH21)
```

Title:
GARCH Modelling

Call:
garchFit(formula = ~arma(2, 1) + garch(2, 1), data = df1, trace = FALSE)

Mean and Variance Equation:
data ~ arma(2, 1) + garch(2, 1)
<environment: 0x1b3aa24c>
[data = df1]

Conditional Distribution:
norm

Coefficient(s):

	mu	ar1	ar2	ma1	omega	alpha1	alpha2	beta1
	1.0800e-01	4.5569e-01	-1.0093e-01	-8.9191e-01	9.8806e+02	1.3389e-01	1.0000e-08	1.0000e-08

Std. Errors:
based on Hessian

Error Analysis:

	Estimate	Std. Error	t value	Pr(> t)
mu	1.080e-01	1.917e-01	0.563	0.5732
ar1	4.557e-01	6.980e-02	6.528	6.65e-11 ***
ar2	-1.009e-01	5.960e-02	-1.693	0.0904 .
ma1	-8.919e-01	3.410e-02	-26.153	< 2e-16 ***
omega	9.881e+02	1.897e+02	5.208	1.91e-07 ***
alpha1	1.339e-01	5.931e-02	2.258	0.0240 *
alpha2	1.000e-08	NA	NA	NA
beta1	1.000e-08	NA	NA	NA

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Log Likelihood:
-1798.259 normalized: -4.926738

Description:
Wed Mar 07 11:57:33 2018 by user: Rina

Standardised Residuals Tests:

	Statistic	p-value
Jarque-Bera Test	308.3263	0
Shapiro-wilk Test	0.94851	5.707702e-10
Ljung-Box Test	Q(10)	0.5232492
Ljung-Box Test	Q(15)	0.4005891
Ljung-Box Test	Q(20)	0.3406755
Ljung-Box Test	R^2 Q(10)	0.04425874
Ljung-Box Test	R^2 Q(15)	0.1687212
Ljung-Box Test	R^2 Q(20)	0.3634543
LM Arch Test	TR^2	0.1408721

Information Criterion Statistics:

AIC	BIC	SIC	HQIC
9.897312	9.982789	9.896378	9.931281

4. ARIMA (2,1,1) GARCH (2,2)

```
> GARCH22 <- garchFit(~ arma(2,1) + garch(2,2), data = df1, trace = FALSE)
Warning message:
In sqrt(diag(fit$cvar)) : NaNs produced
> summary(GARCH22)
```

Title:
GARCH Modelling

Call:
garchFit(formula = ~arma(2, 1) + garch(2, 2), data = df1, trace = FALSE)

Mean and Variance Equation:
data ~ arma(2, 1) + garch(2, 2)
<environment: 0x1b39dbc4>
[data = df1]

Conditional Distribution:
norm

Coefficient(s):

	mu	ar1	ar2	ma1	omega	alpha1	alpha2	beta1
mu	1.0800e-01							
ar1		4.5569e-01						
ar2			-1.0093e-01					
ma1				-8.9191e-01				
omega					9.8806e+02			
alpha1						1.3389e-01		
alpha2							1.0000e-08	
beta1								1.0000e-08

Std. Errors:
based on Hessian

Error Analysis:

	Estimate	Std. Error	t value	Pr(> t)
mu	1.080e-01	2.002e-01	0.540	0.5895
ar1	4.557e-01	6.980e-02	6.528	6.66e-11 ***
ar2	-1.009e-01	5.965e-02	-1.692	0.0906 .
ma1	-8.919e-01	3.503e-02	-25.462	< 2e-16 ***
omega	9.881e+02	2.188e+02	4.516	6.30e-06 ***
alpha1	1.339e-01	6.678e-02	2.005	0.0449 *
alpha2	1.000e-08	NA	NA	NA
beta1	1.000e-08	4.039e-01	0.000	1.0000

beta2	1.000e-08	3.283e-01	0.000	1.0000
-------	-----------	-----------	-------	--------

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Log Likelihood:
-1798.259 normalized: -4.926738

Description:
wed Mar 07 12:05:52 2018 by user: Rina

Standardised Residuals Tests:

	Statistic	p-value
Jarque-Bera Test	Chi^2 308.3263	0
Shapiro-wilk Test	W 0.94851	5.707694e-10
Ljung-Box Test	Q(10) 9.093545	0.5232495
Ljung-Box Test	Q(15) 15.72457	0.4005895
Ljung-Box Test	Q(20) 21.99696	0.3406755
Ljung-Box Test	R^2 Q(10) 18.69885	0.04425874
Ljung-Box Test	R^2 Q(15) 20.08434	0.1687212
Ljung-Box Test	R^2 Q(20) 21.58488	0.3634543
LM Arch Test	TR^2 17.23771	0.1408721

Information Criterion Statistics:

AIC	BIC	SIC	HQIC
9.902791	9.998953	9.901614	9.941007

ESTIMASI MODEL GJR-GARCH

1. GJR-GARCH(1,1)

```
> sp_tarch11 <- garchFit(~ arma(2,1) + garch(1,1), delta = 2, leverage = TRUE, data = df1, trace = FALSE)
> summary(sp_tarch11)
```

Title:
GARCH Modelling

Call:
garchFit(formula = ~arma(2, 1) + garch(1, 1), data = df1, delta = 2,
leverage = TRUE, trace = FALSE)

Mean and Variance Equation:
data ~ arma(2, 1) + garch(1, 1)
<environment: 0x132f9320>
[data = df1]

Conditional Distribution:
norm

Coefficient(s):

	mu	ar1	ar2	ma1	omega	alpha1	gamma1	beta1
	1.0501e-01	4.5836e-01	-1.0307e-01	-8.9116e-01	9.9209e+02	1.2917e-01	5.2366e-02	1.0000e-08

Std. Errors:
based on Hessian

Error Analysis:

	Estimate	Std. Error	t value	Pr(> t)
mu	1.050e-01	1.946e-01	0.540	0.58947
ar1	4.584e-01	7.223e-02	6.346	2.21e-10 ***
ar2	-1.031e-01	6.194e-02	-1.664	0.09612 .
ma1	-8.912e-01	3.452e-02	-25.819	< 2e-16 ***
omega	9.921e+02	3.650e+02	2.718	0.00656 **
alpha1	1.292e-01	9.174e-02	1.408	0.15913
gamma1	5.237e-02	3.047e-01	0.172	0.86355
beta1	1.000e-08	3.322e-01	0.000	1.00000

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Log Likelihood:
-1798.17 normalized: -4.926493

Description:
Wed Mar 07 12:09:08 2018 by user: Rina

Standardised Residuals Tests:

		Statistic	p-Value
Jarque-Bera Test	R	Chi^2	315.8448 0
Shapiro-Wilk Test	R	w	0.9481952 5.215099e-10
Ljung-Box Test	R	Q(10)	8.95725 0.5361654
Ljung-Box Test	R	Q(15)	15.52619 0.4142197
Ljung-Box Test	R	Q(20)	21.74596 0.3544534
Ljung-Box Test	R^2	Q(10)	18.51614 0.04685661
Ljung-Box Test	R^2	Q(15)	19.92831 0.1747
Ljung-Box Test	R^2	Q(20)	21.4327 0.3720693
LM Arch Test	R	TR^2	17.08509 0.1464246

Information Criterion Statistics:

AIC	BIC	SIC	HQIC
9.896821	9.982298	9.895888	9.930791

2. GJR-GARCH (1,2)

```
> sp_tarch12 <- garchFit(~ arma(2,1) + garch(1,2), delta = 2, leverage = TRUE, data = df1, trace = FALSE)
warning message:
In sqrt(diag(fit$cvar)) : NaNs produced
> summary(sp_tarch12)
```

Title:
GARCH Modelling

Call:
garchFit(formula = ~arma(2, 1) + garch(1, 2), data = df1, delta = 2,
leverage = TRUE, trace = FALSE)

Mean and Variance Equation:
data ~ arma(2, 1) + garch(1, 2)
<environment: 0x12432ac0>
[data = df1]

Conditional Distribution:
norm

Coefficient(s):

	mu	ar1	ar2	ma1	omega	alpha1	gamma1	beta1
mu	1.1000e-01	4.8016e-01	-1.1662e-01	-8.8700e-01	1.0560e+03	3.2134e-02	1.0000e+00	1.0000e-08
beta2	1.0000e-08							

Std. Errors:
based on Hessian

Error Analysis:

	Estimate	Std. Error	t value	Pr(> t)
mu	1.100e-01	2.049e-01	0.537	0.5914
ar1	4.802e-01	6.535e-02	7.347	2.02e-13 ***
ar2	-1.166e-01	5.686e-02	-2.051	0.0403 *
ma1	-8.870e-01	3.501e-02	-25.335	< 2e-16 ***
omega	1.056e+03	1.769e+02	5.971	2.36e-09 ***
alpha1	3.213e-02	NA	NA	NA
gamma1	1.000e+00	NA	NA	NA
beta1	1.000e-08	NA	NA	NA
beta2	1.000e-08	2.086e-01	0.000	1.0000

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Log Likelihood:
-1798.644 normalized: -4.927792

Description:
Wed Mar 07 12:11:36 2018 by user: Rina

Standardised Residuals Tests:

	Statistic	p-value
Jarque-Bera Test	Chi^2 336.4605	0
Shapiro-wilk Test	W 0.9479913	4.919694e-10
Ljung-Box Test	Q(10) 8.426617	0.5872403
Ljung-Box Test	Q(15) 14.33746	0.500105
Ljung-Box Test	Q(20) 20.47196	0.4287756
Ljung-Box Test	R^2 Q(10) 16.90206	0.07655934
Ljung-Box Test	R^2 Q(15) 18.3164	0.2463969
Ljung-Box Test	R^2 Q(20) 19.68053	0.4780668
LM Arch Test	TR^2 15.58187	0.2111463

Information Criterion Statistics:

AIC	BIC	SIC	HQIC
9.904899	10.001061	9.903722	9.943115

3. GJR-GARCH (2,1)

```
> sp_tarch21 <- garchFit(~ arma(2,1) + garch(2,1), delta = 2, leverage = TRUE , data = df1, trace = FALSE)
warning message:
In sqrt(diag(fit$cvar)) : NaNs produced
> summary(sp_tarch21)
```

Title:
GARCH Modelling

Call:
garchFit(formula = ~arma(2, 1) + garch(2, 1), data = df1, delta = 2,
leverage = TRUE, trace = FALSE)

Mean and Variance Equation:
data ~ arma(2, 1) + garch(2, 1)
<environment: 0x13959afc>
[data = df1]

Conditional Distribution:
norm

Coefficient(s):

	mu	ar1	ar2	ma1	omega	alpha1	alpha2	gamma1
	1.0546e-01	4.5935e-01	-1.0370e-01	-8.9105e-01	9.9562e+02	1.2488e-01	1.0000e-08	6.0960e-02
		gamma2	beta1					
		-3.3554e-01	1.0000e-08					

Std. Errors:
based on Hessian

Error Analysis:

	Estimate	Std. Error	t value	Pr(> t)
mu	1.055e-01	1.949e-01	0.541	0.58842
ar1	4.594e-01	7.192e-02	6.387	1.7e-10 ***
ar2	-1.037e-01	6.191e-02	-1.675	0.09393 .
ma1	-8.910e-01	3.452e-02	-25.811	< 2e-16 ***
omega	9.956e+02	3.834e+02	2.597	0.00941 **
alpha1	1.249e-01	8.994e-02	1.388	0.16499
alpha2	1.000e-08	NA	NA	NA
gamma1	6.096e-02	3.173e-01	0.192	0.84765
gamma2	-3.355e-01	3.037e+00	-0.110	0.91202
beta1	1.000e-08	3.479e-01	0.000	1.00000

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Log Likelihood:
-1798.238 normalized: -4.92668

Description:
Wed Mar 07 12:17:34 2018 by user: Rina

Standardised Residuals Tests:

	Statistic	p-value
Jarque-Bera Test	R chi^2 316.8503	0
Shapiro-wilk Test	R w 0.9481437	5.138754e-10
Ljung-Box Test	R Q(10) 8.934808	0.5383015
Ljung-Box Test	R Q(15) 15.4685	0.4182258
Ljung-Box Test	R Q(20) 21.69004	0.357564
Ljung-Box Test	R^2 Q(10) 18.42209	0.04824747
Ljung-Box Test	R^2 Q(15) 19.83098	0.1785128
Ljung-Box Test	R^2 Q(20) 21.3252	0.3782188
LM Arch Test	R TR^2 16.99406	0.1498209

Information Criterion Statistics:

AIC	BIC	SIC	HQIC
9.908155	10.015001	9.906706	9.950617

4. GJR-GARCH (2,2)

```
> sp_tarch22 <- garchFit(~ arma(2,1) + garch(2,2), delta = 2, leverage = TRUE , data = df1, trace = FALSE)
Warning message:
In sqrt(diag(fit$scvar)) : NaNs produced
> summary(sp_tarch22)
```

Title:
GARCH Modelling

Call:
garchFit(formula = ~arma(2, 1) + garch(2, 2), data = df1, delta = 2,
leverage = TRUE, trace = FALSE)

Mean and Variance Equation:
data ~ arma(2, 1) + garch(2, 2)
<environment: 0x12170a18>
[data = df1]

Conditional Distribution:
norm

Coefficient(s):

	mu	ar1	ar2	ma1	omega	alpha1	alpha2	gamma1
gamma1	1.1000e-01	4.8016e-01	-1.1662e-01	-8.8700e-01	1.0560e+03	3.2134e-02	1.0000e-08	1.0000e+00
gamma2	NA	NA	NA	NA	NA	NA	NA	NA
beta1	1.000e+00	4.611e-01	1.878	0.0604	NA	NA	NA	NA
beta2	8.658e-01	2.086e-01	0.000	1.0000	NA	NA	NA	NA

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Log Likelihood:
-1798.644 normalized: -4.927792

Description:
Wed Mar 07 12:24:44 2018 by user: Rina

Standardised Residuals Tests:

	Statistic	p-value
Jarque-Bera Test	336.4605	0
Shapiro-wilk Test	0.9479913	4.919693e-10
Ljung-Box Test	8.426617	0.5872404
Ljung-Box Test	14.33745	0.5001051
Ljung-Box Test	20.47197	0.4287754
Ljung-Box Test	16.90207	0.07655928
Ljung-Box Test	18.3164	0.2463967
Ljung-Box Test	19.68053	0.4780666
LM Arch Test	15.58187	0.2111462

Information Criterion Statistics:

AIC	BIC	SIC	HQIC
9.915858	10.033389	9.914111	9.962566

LAMPIRAN 4


Peramalan Beban Puncak Listrik untuk 10 periode kedepan

```
> forecast.tarch11<-forecast(Bp$beban,level = 10)
> forecast.tarch11
      Point Forecast      Lo 10      Hi 10
367      974.5213  969.8403  979.2023
368      974.5213  969.6727  979.3698
369      974.5213  969.5108  979.5318
370      974.5213  969.3539  979.6887
371      974.5213  969.2016  979.8410
372      974.5213  969.0535  979.9891
373      974.5213  968.9093  980.1332
374      974.5213  968.7688  980.2738
375      974.5213  968.6315  980.4110
376      974.5213  968.4974  980.5452
```

LAMPIRAN 5

T Tabel

Percentile Values ($t_{\alpha, v}$) for the t Distribution with v Degrees of Freedom
(Shaded Area = α)



v	α									
	0.995	0.99	0.975	0.95	0.9	0.8	0.75	0.7	0.6	0.55
1	63.6567	31.8205	12.7062	6.3138	3.0777	1.3764	1.0000	0.7265	0.3249	0.1584
2	9.9248	6.9646	4.3027	2.9200	1.8856	1.0607	0.8165	0.6172	0.2887	0.1421
3	5.8409	4.5407	3.1824	2.3534	1.6377	0.9785	0.7649	0.5844	0.2767	0.1366
4	4.6041	3.7469	2.7764	2.1318	1.5332	0.9410	0.7407	0.5686	0.2707	0.1338
5	4.0321	3.3649	2.5706	2.0150	1.4759	0.9195	0.7267	0.5594	0.2672	0.1322
6	3.7074	3.1427	2.4469	1.9432	1.4398	0.9057	0.7176	0.5534	0.2648	0.1311
7	3.4995	2.9980	2.3646	1.8946	1.4149	0.8960	0.7111	0.5491	0.2632	0.1303
8	3.3554	2.8965	2.3060	1.8595	1.3968	0.8889	0.7064	0.5459	0.2619	0.1297
9	3.2498	2.8214	2.2622	1.8331	1.3830	0.8834	0.7027	0.5435	0.2610	0.1293
10	3.1693	2.7638	2.2281	1.8125	1.3722	0.8791	0.6998	0.5415	0.2602	0.1289
11	3.1058	2.7181	2.2010	1.7959	1.3634	0.8755	0.6974	0.5399	0.2596	0.1286
12	3.0545	2.6810	2.1788	1.7823	1.3562	0.8726	0.6955	0.5386	0.2590	0.1283
13	3.0123	2.6503	2.1604	1.7709	1.3502	0.8702	0.6938	0.5375	0.2586	0.1281
14	2.9768	2.6245	2.1448	1.7613	1.3450	0.8681	0.6924	0.5366	0.2582	0.1280
15	2.9467	2.6025	2.1314	1.7531	1.3406	0.8662	0.6912	0.5357	0.2579	0.1278
16	2.9208	2.5835	2.1199	1.7459	1.3368	0.8647	0.6901	0.5350	0.2576	0.1277
17	2.8982	2.5669	2.1098	1.7396	1.3334	0.8633	0.6892	0.5344	0.2573	0.1276
18	2.8784	2.5524	2.1009	1.7341	1.3304	0.8620	0.6884	0.5338	0.2571	0.1274
19	2.8609	2.5395	2.0930	1.7291	1.3277	0.8610	0.6876	0.5333	0.2569	0.1274
20	2.8453	2.5280	2.0860	1.7247	1.3253	0.8600	0.6870	0.5329	0.2567	0.1273
21	2.8314	2.5176	2.0796	1.7207	1.3232	0.8591	0.6864	0.5325	0.2566	0.1272
22	2.8188	2.5083	2.0739	1.7171	1.3212	0.8583	0.6858	0.5321	0.2564	0.1271
23	2.8073	2.4999	2.0687	1.7138	1.3195	0.8575	0.6853	0.5317	0.2563	0.1271
24	2.7969	2.4922	2.0639	1.7109	1.3178	0.8569	0.6848	0.5314	0.2562	0.1270
25	2.7874	2.4851	2.0595	1.7081	1.3163	0.8562	0.6844	0.5312	0.2561	0.1269
26	2.7787	2.4786	2.0555	1.7056	1.3150	0.8557	0.6840	0.5309	0.2560	0.1269
27	2.7707	2.4727	2.0518	1.7033	1.3137	0.8551	0.6837	0.5306	0.2559	0.1268
28	2.7633	2.4671	2.0484	1.7011	1.3125	0.8546	0.6834	0.5304	0.2558	0.1268
29	2.7564	2.4620	2.0452	1.6991	1.3114	0.8542	0.6830	0.5302	0.2557	0.1268
30	2.7500	2.4573	2.0423	1.6973	1.3104	0.8538	0.6828	0.5300	0.2556	0.1267
40	2.7045	2.4233	2.0211	1.6839	1.3031	0.8507	0.6807	0.5286	0.2550	0.1265
50	2.6778	2.4033	2.0066	1.6759	1.2987	0.8489	0.6794	0.5278	0.2547	0.1263
60	2.6587	2.3739	1.9901	1.6641	1.2922	0.8461	0.6776	0.5265	0.2542	0.1261
100	2.6259	2.3642	1.9840	1.6602	1.2901	0.8452	0.6770	0.5261	0.2540	0.1260
200	2.6006	2.3451	1.9719	1.6528	1.2858	0.8434	0.6757	0.5252	0.2537	0.1258
300	2.5923	2.3388	1.9679	1.6499	1.2844	0.8428	0.6753	0.5250	0.2536	0.1258
400	2.5862	2.3357	1.9659	1.6487	1.2837	0.8425	0.6751	0.5248	0.2535	0.1257
600	2.5840	2.3326	1.9639	1.6474	1.2830	0.8422	0.6749	0.5247	0.2535	0.1257
1000	2.5808	2.3301	1.9623	1.6464	1.2824	0.8420	0.6747	0.5246	0.2534	0.1257



BIOGRAFI

Nama Lengkap Nurzarina, sering dipanggil Rina. Saya lahir di Malaysia 16 April 1996. Saya merupakan anak sulung dari 5 bersaudara dan merupakan anak dari sepasang Ayah Basri dan Ibu Sitti Aminah. Saya mulai bersekolah pada tahun 2001 di SDN 037 INP Buttu Dukka dan berakhir pada tahun 2007. Kemudian saya melanjutkan ke jenjang tingkat SMPN 1 Wonomulyo pada tahun 2007 dan berakhir pada tahun 2010. Setelah itu saya melanjutkan ke tingkat SMAN 1 Wonomulyo pada tahun 2010 dan berakhir pada tahun 2013. Kemudian saya mengikuti seleksi SNMPTN yang diadakan pada waktu itu dan saya lolos masuk ke PTN UIN Alauddin Makassar dan diterima di Jurusan Matematika Fakultas Sains Dan Teknologi dan selesai pada tahun 2018.

UNIVERSITAS ISLAM NEGERI
ALAUDDIN
M A K A S S A R